

Sveučilište u Zagrebu
Fakultet strojarstva i brodogradnje

DIPLOMSKI RAD

Sanja Rakijašić

Zagreb, 2010.

Sveučilište u Zagrebu
Fakultet strojarstva i brodogradnje

DIPLOMSKI RAD

Voditelj rada:
Doc.dr.sc.Biserka Runje

Sanja Rakijašić

Zagreb, 2010.

ZAHVALA

Profesorici Biserki Runje zahvaljujem na pomoći i mentorstvu prilikom izrade ovog rada.

IZJAVA

Izjavljujem da sam ovaj rad izradila samostalno koristeći stečeno znanje tijekom studija i navedenu literaturu, te uz stručnu pomoć i savjete svog mentora.

Sanja Rakijašić

SAŽETAK

U ovom radu daje se sažet prikaz zaštite od požara s naglaskom na protupožarne premaze. Posebno se osvrćemo na protupožarni premaz „Hensotherm“ proizvođača HEMPELA, te se obrađuju njegove karakteristike i opisuje se metoda simulacije požara po normi 4102-2 kojom se utvrđuje postojanost i sigurnost objekata zaštićenih ovim premazom. Također se daje uvid u metode ispitivanja debljine premaza, te se opisuje standardizacija uređaja „Elcometer“ koji je korišten pri mjerenju debljine protupožarnog premaza.

Također su dane statističke metode i alati za praćenje i poboljšavanje procesa, te je analizirana procjena sposobnosti procesa nanošenja protupožarnog premaza na čeličnoj konstrukciji zgrade Euroherc, Zagreb.

Ciljevi primjene ovakvih postupaka u kontroli kvalitete su razumijevanje postupanja sa podacima, dovođenje procesa u stanje statističke kontrole, utvrđivanje pomaka procesa, te dobivanje saznanja o mogućnostima poboljšavanja.

Iz izvršene analize podataka možemo zaključiti da je proces nanošenja protupožarnog premaza sposoban i da se može koristiti za danu konstrukciju u navedenim uvjetima.

Pravilnim korištenjem navedenih metoda i alata u analizi dolazimo do podataka koji omogućuju tehnologu i radniku u proizvodnji kvalitetniju pripremu proizvodnje, te lakše predviđanje eventualnih grešaka tokom proizvodnje.

Mjerenjem se skuplja određeno iskustvo koje može poboljšati buduću kvalitetu rada, te time izbjegavanje nepotrebnih gubitaka, naročito u ekonomskom smislu.

KLJUČNE RIJEČI

Kontrola kvalitete; statistička kontrola procesa; protupožarni premazi; metode mjerenja premaza; sposobnost procesa; analiza; statističke razdiobe;

OZNAKE

\bar{x}_i - aritmetička sredina uzoraka

R_i - raspon uzoraka

n - veličina uzorka

\bar{G}_D G kontrolne granice (donja i gornja)

\bar{s}^- - aritmetička sredina standardnih odstupanja svih uzoraka

α - razina značajnosti

$\text{erf}(z)$ - funkcija pogreške

H_0 - nulta hipoteza

H_1 - alternativna hipoteza

λ - transformacijski parametar

$\sigma^2(\lambda)$ - standardna devijacija transformirane varijable \tilde{x}

C_p, C_{pk}, C_r .- sposobnost procesa u kratkom vremenskom razdoblju (short term)

P_p, P_{pk} i P_r - sposobnost procesa u duljem vremenskom razdoblju (long term)

PPM- podatak o dijelovima na milijun

USL, LSL- specificirana ograničenja procesa

POPIS SLIKA

Slika 1. Odnos naprezanja i deformacija uz povećanje temperature za armaturni čelik.....	4
Slika 2. Ovisnost pada modula elastičnosti uz povećanje temperature za armaturni čelik.....	4
Slika 3. Premaz prije (lijevo) i pod utjecajem vatre (desno).....	5
Slika 4. Oštećenje premaza pri transportu.....	9
Slika 5. Izgled profila (4.40m) koji se koristi za ispitivanje	11
Slika 6. Snimka profila, zaštićen Hensothermom 3KS nakon 30 minuta (temperatura je viša od 600° C)	12
Slika 7. Izgled čeličnih profila nakon hlađenja	13
Slika 8. Podjela nedestruktivnih metoda	17
Slika 9. Elcometer 456	19
Slika 10. Prodiranje vrtložnih struja kod različitih debljina premaza	20
Slika 11. Rukovanje Elcometrom.....	22
Slika 12. Slučajne, sistemske varijacije i veza sa distribucijom	23
Slika 13. Načini varijacija distribucija	24
Slika 14. Sustav kontrole procesa	25
Slika 15. Tipovi varijacija procesa	26
Slika 16 . Erf funkcija pogreške	39
Slika 17. Anderson- Darling test	44
Slika 18. Anderson –Darling test u programskom paketu Minitab.....	45
Slika 19. Probability plot of warping	47
Slika 20. Transformacija podataka uporabom Box- Cox metode	49
Slika 21. Box-Cox transformacija distribucija	51
Slika 22. Ovisnost promjene λ ovisno o prirodi distribuciji.....	52
Slika 23. Box-Cox plot of warping - lambda	52
Slika 24. Probability plot - podaci nakon Box-Cox transformacije	53
Slika 25. Probability plot of warping; C2	54
Slika 26. Prikaz sposobnosti procesa	60
Slika 27. Tumačenje sposobnosti procesa.....	64
Slika 28. Process capability of warping	65
Slika 29. Process capability of warping	67
Slika 30. Process capability of warping	69
Slika 31. Utjecaj parametara na oblik Lognormalne raspodjele	71
Slika 32. Process capability of warping	72
Slika 33. Čelična konstrukcija.....	73
Slika 34. Glavni nosač.....	75
Slika 35. Sporedni nosači	76
Slika 36. $X - R$ karta glavnog nosača 1; veličina uzorka: 5	77
Slika 37. $X - R$ karta glavnog nosača 1, nakon eliminacije uzorka 8.	78
Slika 38. $X - R$ karta sporednih nosača 1.	79
Slika 39. Probability plot glavnog nosača 1.....	80
Slika 40. Probability plot sporednih nosača 1	81
Slika 41. Određivanje lambde za glavni nosač 1	82

Slika 42. Određivanje lambde za sekundarne nosače.....	82
Slika 43. Podaci glavnog nosača nakon Box-Cox transformacije	83
Slika 44. Podaci sporednih nosača nakon Box-Cox transformacije.....	84
Slika 45. Sposobnost procesa glavnog nosača	85
Slika 46. Sposobnost procesa sporednih nosača	86
Slika 47. Sposobnost procesa glavnog nosača 1 prema Taguchi-u.....	87
Slika 48. Sposobnost sporednih nosača prema Taguchi-u	87
Slika 49. Sposobnost procesa uporabom Weibullove razdiobe (glavni nosač 1).....	89
Slika 50. Sposobnost procesa uporabom Weibullove razdiobe (sporedni nosači 1).....	89
Slika 51. Sposobnost procesa uporabom Lognormalne razdiobe (glavni nosač 1).....	91
Slika 52. Sposobnost procesa uporabom Lognormalne razdiobe (sporedni nosači 1).....	91

POPIS TABLICA

Tablica 1. Koeficijenti kontrolnih granica za \bar{x} -R kontrolnu kartu.....	31
Tablica 2. Koeficijenti kontrolnih granica za \bar{x} -s kontrolnu kartu.....	33
Tablica 3. Rezultati mjerenja savijanja pločica.....	36
Tablica 4. Parametri oblika k za distribucijske modele	68
Tablica 5. Debljine premaza u (mm) na glavnom nosaču 1.....	75
Tablica 6. Debljine premaza u (mm) na sporednom nosaču 1	76

SADRŽAJ

1.	Uvod.....	1
2.	Tehnologija nanošenja protupožarnog premaza i metode ispitivanja debljine premaza u postupku zaštite od požara čeličnih konstrukcija.....	3
2.1	Zaštita od požara.....	3
2.2	Čelici u graditeljstvu.....	3
2.3	Premazi	5
2.4	Tehnički podaci o protupožarnom premazu „HENSOTHERM 3KS“	6
2.4.1	Priprema površine	6
2.4.2	Sustav zaštite	7
2.4.3	Nanošenje	8
2.4.4	Saniranje oštećenja	8
2.4.5	Mjere sigurnosti i posebne napomene	9
2.5	Laboratorijsko ispitivanje protupožarnog premaza prema normi DIN 4102-2	10
2.5.1	Dokazivanje razreda otpornosti na požar ispitivanjem	10
2.5.2	Provedba ispitivanja	11
2.6	Metode ispitivanja debljina nanosa boja nedestruktivnim metodama.....	14
2.6.1	Nedestruktivne metode.....	15
2.6.2	Potrebni uvjeti za osiguranje mjerne obnovljivosti kod etalon pločice	16
2.6.3	Podjela nedestruktivnih metoda	17
2.6.4	Mjerenje debljine premaza „MIKROTEST“; magnetska metoda.....	17
2.6.5	Mjerenje debljine premaza pomoću instrumenta „ELCOMETER“	18
3.	Teorijska razrada sposobnosti procesa.....	23
3.1	Statistička kontrola procesa	23
3.1.1	Centralni granični teorem.....	24
3.1.2	Prevenција protiv otkrivanja	25
3.1.3	Slučajni i sistemski uzroci varijacija.....	26
3.2	Kontrolne karte	27
3.2.1	\bar{x} -R karta.....	29
3.2.2	\bar{x} -s karta.....	31
3.3	Normalna distribucija i testiranje hipoteza.....	34
3.3.1	Analiza sposobnosti procesa sa nenormaliziranim podacima	34
3.3.2	Normalizacija podataka.....	35
3.4	Primjer	36

3.5	Prva faza razrade primjera	37
3.5.1	Teorijska razrada p-vrijednosti i Anderson-Darling testa	37
3.5.2	Anderson-Darling statistika.....	41
3.5.3	Analiza podataka u programskom paketu Minitab (p-value, AD)	47
3.5.4	Teorijska razrada Box-Cox transformacije	48
3.5.5	Analiza podataka u programskom paketu Minitab (lambda, probability plot nakon Box-Cox transformacije)	52
3.6	Druga faza.....	55
3.6.1	Teorijska razrada sposobnosti procesa	55
3.6.2	Analiza podataka sposobnosti procesa	65
3.6.3	Teoretska razrada Taguchi-evih principa	66
3.6.4	Analiza podataka uporabom Taguchi-evih principa	67
3.7	Treća faza	68
3.7.1	Teoretska razrada Weibullove razdiobe	68
3.7.2	Analiza procesa uporabom Weibullove razdiobe.....	69
3.7.3	Teoretska razrada Lognormalne razdiobe	70
3.7.4	Analiza procesa uporabom Lognormalne razdiobe.....	72
4.	Analiza podataka i procjena sposobnosti procesa protupožarnog premaza	73
4.1	Analiza protupožarnog premaza $X - R$ kartom	77
4.2	p-vrijednost, AD analiza.....	80
4.3	Procjena vrijednosti lambda	82
4.4	Podaci nakon box-cox transformacije	83
4.5	Analiza podataka sposobnosti procesa	85
4.6	Analiza podataka uporabom Taguchi-evih principa.....	87
4.7	Analiza procesa uporabom Weibullove razdiobe	89
4.8	Analiza procesa uporabom Lognormalne razdiobe	91
5.	Zaključak	93
6.	Literatura	95

1. UVOD

Životna iskustva nas upozoravaju da u svakom trenutku možemo računati sa nastajanjem požara. Upravo zato, obvezni smo sukladno pravilima struke i zakonske regulative omogućiti adekvatnu zaštitu od požara. Time osiguravamo nesmetano i sigurno napuštanje građevine, te umanjeње materijalne štete. Vrsta zaštite upravo ovisi o namjeni objekta, što ukazuje da pri samom konstruiranju zgrade potrebno je voditi računa o adekvatnoj zaštiti.

U ovom radu se u prvom dijelu daje sažet prikaz zaštite od požara s posebnim naglaskom na protupožarne premaze koji su i temelj ovog rada. Posebno se osvrćemo na protupožarni premaz „Hensotherm“ proizvođača HEMPELA, te se posebno obrađuju njegove karakteristike i opisuje se metoda simulacije požara po normi 4102-2 kojom se utvrđuje postojanost i sigurnost objekata zaštićenih ovim premazom. Također se daje uvid u metode ispitivanja debljine premaza, te se opisuje standardizacija uređaja „Elcometer“ koji je korišten pri mjerenju debljine protupožarnog premaza.

Posebno je važan dio rada gdje se na konkretnom primjeru (čeličnoj konstrukciji nadgradnje objekta EUROHERCA u Zagrebu – zaštićena je premazom klase F90) mjerenjem, te kontrolom pomoću $\bar{X} - R$ karte utvrđuje kvaliteta nanesenog premaza. (Ispitivanje i kontrola vršena prema propisima – norme proizvođača premaza, protupožarni pravilnik). Također se vrši statistička kontrola sposobnosti procesa.

Za uspješno provođenje kontrole kvalitete potrebno je razumjeti statističke tehnike koje se koriste. Kada se podaci ponašaju sukladno normalnoj distribuciji, relativno je jednostavno pomoću faktora sposobnosti procesa ocijeniti prirodu sposobnosti procesa.

Kako podaci iz procesa nisu uvijek normalno distribuirani, potrebno je provesti niz postupaka kako bi bilo moguće ocijeniti sposobnost procesa. Upravo su ti postupci cilj ovog rada. Opisani su postupci izvršavanja normalizacije podataka, te uporaba drugih distribucija (Weibull, Lognormalna).

Kroz praktičan primjer ujedno je razrađeno praktično rješenje računalnim alatom Minitab, koji je rješavan u više faza. U prvoj fazi je ispitana priroda ponašanja podataka, gdje je zaključeno da se podaci ne pokoravaju normalnoj distribuciji, te je izvršena njihova

normalizacija. Ujedno je izvršena Box-Cox transformacija koja pretvara dobivene podatke u aproksimacijski set podataka.

Detaljno je razrađena problematika sposobnosti procesa. Korištenjem Box-Cox transformacije podaci su normalizirani, te su dani zaključci o sposobnosti procesa. Potom se pomoću Taguchi-jevih principa pristupilo poboljšanju procesa.

Kako je jedan od postupaka postupanja s nenormalnim podacima uporaba drugih distribucija, dan je uvid u teoriju Weibullove i Lognormalne distribucije, te je izvršena procjena sposobnosti procesa na temelju dobivenih podataka.

Ciljevi primjene ovakvih postupaka u kontroli kvalitete su razumijevanje postupanja sa podacima, dovođenje procesa u stanje statističke kontrole, utvrđivanje pomaka procesa, te dobivanje saznanja o mogućnostima poboljšavanja.

2. TEHNOLOGIJA NANOŠENJA PROTUPOŽARNOG PREMAZA I METODE ISPITIVANJA DEBLJINE PREMAZA U POSTUPKU ZAŠTITE OD POŽARA ČELIČNIH KONSTRUKCIJA

2.1 ZAŠTITA OD POŽARA

Činjenica da je požar jedna od prvih bitnih točaka pri samom projektnom zadatku govori sam „Zakon o gradnji“. Zahtjevi koji se danas postavljaju pred građevinski objekt za područje protupožarne zaštite u Europi u pravilu su daleko iznad zahtjeva koje pred objekt postavljaju kriteriji statike, te se danas u projektiranju drži da kada se zadovolje protupožarni zahtjevi, da su u pravilu zadovoljeni i zahtjevi statike.

Stoga je vrlo važno poznavati požarne opasnosti, te uzroke nastajanja požara za olakšavanje provedbe i odabira mjere zaštite. Najveće uštede na ovom području, a i jedini pravi put ka sigurnom objektu je planiranje zaštite od požara u svim fazama njezinog projektiranja.


2.2 ČELICI U GRADITELJSTVU

Uporaba čelika u graditeljstvu je vrlo velika. Koristi se kao građevni materijal za čelične konstrukcije te kao betonski čelik u armiranobetonskim konstrukcijama jer dobro podnosi i tlačna i vlačna naprezanja. Osnovne karakteristike čelika su elastičnost, plastičnost, čvrstoća i žilavost.


Uslijed povišenih temperatura dolazi do deformacija čeličnih elemenata, u obliku povećanja njihove duljine. Uslijed produljenja može doći do rušenja dijelova građevine na koje je kruto vezan neki nezaštićeni čelični nosač. Osim što se povećanjem temperature elementi izdužuju, kod isključivo čeličnih konstrukcija problem kod povišenih temperatura je i druge prirode.

S povećanjem temperature padaju osnovne mehaničke karakteristike: čvrstoća, granica popuštanja i modul elastičnosti. Zbog pada prve dvije osnovne karakteristike dolazi do smanjenja mogućnosti nošenja čeličnih elemenata, a zbog pada modula elastičnosti do povećanja progiba, odnosno deformacija. Iznad temperature od 300 °C to smanjenje postaje značajno te se smatra da kod oko 600 °C čelik ima zanemarivo malu nosivost.

Za meki (armaturni) čelik dolazi do porasta čvrstoće u intervalu od početne temperature do temperature od oko 300 °C, ali nakon toga čvrstoća progresivno pada, da bi kod 550 °C iznosila svega 50% čvrstoće od početne vrijednosti, pri čemu dolazi do velikog rastezanja i vitoperenja konstrukcije [1].



Slika 1. Odnos naprezanja i deformacija uz povećanje temperature za armaturni čelik



Slika 2. Ovisnost pada modula elastičnosti uz povećanje temperature za armaturni čelik


Da bi se poboljšala svojstva čeličnih konstrukcija u požaru, provodi se zaštita; obzidavanjem, ubetoniravanjem, žbukanjem, oblaganjem ili premazivanjem, a rjeđe sofisticiranijim sustavima unutarnjeg hlađenja profila vodom (vrijedi isključivo za zatvorene cijevne profile).

2.3 PREMAZI

Osnovna funkcija protupožarnog premaza na čeličnim nosivim elementima je sprečavanje zagrijavanja osnovnog materijala u što dužem vremenu do maksimalno 500° C (ovisno o postavljenim zahtjevima proizvođača, te normi po kojoj se nanosi premaz). Tako premaz u svojoj funkciji predstavlja izolator tj. toplinsku izolaciju.

Protupožarni premaz je po svom kemijskom sastavu antioksidans, pod djelovanjem vatre povećava svoj volumen, tj. ekspandira, te tako odbacuje ili udaljava toplinski udar na površini konstrukcije u toku požara. Povećavanje volumena ide i više od 100 puta [2].

Tako se sloj debljine 1 mm može povećati u zaštitni sloj pepelastog krutog nanosa od oko 100 do 150 mm pod djelovanjem vatre (Slika 3.).



Slika 3. Premaz prije (lijevo) i pod utjecajem vatre (desno)

Protupožarnim premazima možemo zaštititi konstrukciju u vremenskom trajanju od 30, 60, 90 min, ovisno o zahtjevima koji se traže. Za traženu minutažu treba prema certifikatu za premaz, koji daje proizvođač, te prema normama propisno nanijeti premaz. Poštivanjem tih propisa premaz bi trebao štititi konstrukciju za odabrano vrijeme.

Proizvođači protupožarnih premaza:

- HEMPEL doo. – (HENSOTHERM) ; Protupožarna zaštita za klasu F90- korišteno za zaštitu objekta Euroherc
- HEMPEL doo. – (CONTRAFLAM S)
- CROMOS- (PIROSTOP)

2.4 TEHNIČKI PODACI O PROTUPOŽARNOM PREMAZU „HENSOTHERM 3KS“

2.4.1 PRIPREMA POVRŠINE

Čelične površine moraju biti čiste i ne smiju sadržavati hrđu i okujinu. Obavezno je čišćenje mlazom abraziva (sačmarenje) prema ISO 8501.1 ili UNE-EN-ISO 08502-3-200 standardima, jer će to u protivnome, loše djelovati na rasprskavanje kristala u slučaju vatre kao i na adheziju stvorene pjene na podlozi. Tokom pripreme i nanošenja boje temperatura površine mora iznositi najmanje 3°C iznad rosišta kako bi se izbjegla kondenzacija i osigurala adhezija.

2.4.2 SUSTAV ZAŠTITE

- HEMPADUR 15570/5063-TEMELJ; dvokomponentna je boja, koja se skrućuje poliamidnim aduktom. Otvrđnjavanjem prerasta u snažan, iznimno antikorozivan premaz na temperaturama sve do -10°C . Aplicira se neposredno nakon sačmarenja. Prije nego što se nanese protupožarni premaz HENSOTHERM 3KS potrebno je pričekati minimalno 24 sata. Ostali organski temelji poput alkida, klorkaučuka, vinila, epoksi estera i akrila se ne preporučuju jer su najosjetljiviji na toplinu i mogu imati negativnog utjecaja na ponašanje premaza u slučaju požara.
- HENSOTHERM 3KS-PROTUPOŽARNI PREMAZ; premaz na bazi otapala koji je namijenjen sprečavanju širenja vatre. Ne sadrži klor. Pod utjecajem topline on stvara mikroporoznu ugljičnu masu sa svojstvom izolacije koja štiti čelik od prekomjernog porasta temperature i gubitka konstrukcijske stabilnosti. Pri nanošenju minimalna temperatura mora biti 5°C i relativna vlažnost do 80%. Licenciran je za konstrukcijski čelik kao što su stupovi od lijevanog željeza, čelični nosači, čelični okviri te rešetkasti elementi s otvorenim i zatvorenim profilima u zatvorenim prostorijama i na otvorenom. Iz toga se izuzimaju čelične konstrukcije koje su trajno izložene velikoj vlazi ili agresivnim plinovima.
- HEMPATEX ENAMEL 56360- ZAVRŠNI PREMAZ; završna je boja na bazi akrilne smole i nekloriranog plastifikatora koji joj daje svojstvo izvanrednog zadržavanja sjaja i nijanse. Suši se fizikalnim putem. Otporna je na slanu vodu i na dodir sa alifatskim ugljikovodicima, te biljnim i životinjskim uljima. Završni premaz ne smije se nanositi dok se HENSOTHERM 3KS nije dobro osušio. Uglavnom se aplicira u dva sloja: prvi sloj u radionici i drugi (tkz. kozmetički) nakon ugradnje [3].

2.4.3 NANOŠENJE

- Jedan premaz epoksidnog temelja HEMPADUR u debljini suhog filma od 30/50 μm
- HENSOTHERM 3KS; debljina prema faktoru profila sekcije i tražene stabilnosti na vatru
- Jedan ili dva premaza, prema dogovoru, završnog premaza HEMPATEX ENAMEL u debljini suhog filma od 30 μm

Nanošenje se vrši valjkom, kistom ili bezračnom špricom. Valjkom ili kistom moguće je na vertikalne površine nanijeti jedan premaz u debljini od 500 g/m^2 .

Pri nanošenju špricom, HENSOTHERM 3KS se može razrijediti sa maksimalno 5% razrjeđivač V45. Preporuča se otvor sapnice 0.017-0.025 mm i pritisak od 200-250 bara. Bezračnom špricom moguće je u jednom premazu nanijeti do 1000 g/m^2 . Premaz nanesen ovom tehnologijom ne mora biti jednolično, u smislu debljine raspoređen po površini. Varijacija debljine može biti različite vrijednosti, stoga je nužno povoljno prilagoditi parametre kod špricanja (tlak, gustoću premaza, temperaturu prostorije). Lošim načinom nanošenja premaza utrošiti će se više boje kako bi se postigla minimalno potrebna debljina, a to predstavlja nepotrební trošak. Isto tako predebelim slojem premaza može doći i do zadržavanja otapala unutar premaza, pucanja premaza zbog smanjene elastičnosti, dugotrajnog sušenja [3].

2.4.4 SANIRANJE OŠTEČENJA

- Izvršiti vizualni pregled
- Sav oštećen protupožarni premaz potrebno je ukloniti špatulom, nožem, brusnim papirima
- Rubove zdravog premaza do oštećenih mjesta zakositi i prebrusiti brusnim papirom
- Otprašiti površine

- Reparturni HENSOTHERM MASTIC 3KS direktno je apliciran na HEMPADUR špatulom u više nanosa do inicijalne debljine (cca 3mm)
- Finim brusnim papirom uravnotežena je oštećena površina
- Završni HEMPATEX ENAMEL u debljini od 30 μ m apliciran je valjkom
- Vizualnim pregledom utvrditi da je premaz u potpunosti zatvoren i da su oštećenja kvalitetno sanirana
- Izuzetno je važno naglasiti da se sanacija vrši uz prisutstvo i kontrolu inspektora proizvođača premaza



Slika 4. Oštećenje premaza pri transportu

2.4.5 MJERE SIGURNOSTI I POSEBNE NAPOMENE

- Izbjegavati udisanje mogućih para otapala i čestice boje, te dodir tekuće boje s kožom i očima. Kad se boja nanosi u skučenom prostoru ili tamo gdje je zrak ustajao, potrebno je osigurati pojačanu ventilaciju. Preporuča se i uporaba sredstava za zaštitu dišnih organa, kože i očiju kada se boja nanosi raspršivačem. Potrebno je poduzeti potrebne mjere opreza u vezi s opasnošću od eksplozije i požara.

- Premaz koristiti isključivo uz primjenu certifikata koji daje proizvođač, te u uvjetima koji on propisuje. Ponašanje, u odnosu na djelovanje vatre u uvjetima drukčijim od onih koji su specificirani u izvješću nije bilo ispitano te se iz tog razloga ne preporučaju.

2.5 LABORATORIJSKO ISPITIVANJE PROTUPOŽARNOG PREMAZA PREMA NORMI DIN 4102-2

Ispitivanja su provedena u svrhu procjene otpornosti na vatru čeličnih greda i stupova zaštićenih sa premazima različitih debljina. Ispitivanja su vršena u komori gdje je temperatura dosegala i više od 900°C [4]. Bitno je da su komora, nosači, opterećenje na nosačima, te samo gašenje izvedeno u uvjetima koji bi mogli odgovarati realnim uvjetima požara. Na taj način možemo stvarno procijeniti izdržljivost protupožarnog premaza u kategoriziranom vremenu.

Ispitivanje je izvršeno u skladu sa normom 4102-2.

2.5.1 DOKAZIVANJE RAZREDA OTPORNOSTI NA POŽAR ISPITIVANJEM

Za svrstavanje u razred otpornosti na požar mjerodavan je najnepovoljniji rezultat ispitivanja na najmanje dva pokusna primjerka. Za određivanje otpornosti pregradnih građevnih elemenata koji se ne smiju tijekom ispitivanja u određenom vremenskom razdoblju (koje prepisuje razred otpornosti) ugrijati na požaru iznad dopuštene temperature sa svih strana, te moraju dodatno izdržati zahtjeve ispitane čvrstoće. Građevni elementi se za vrijeme pokusa ne smiju urušiti pod računski ustanovljenim dopuštenim opterećenjem, ako su nosivi ili pod opterećenjem vlastite mase, ako nisu nosivi. Razredima otpornosti F (30,60,90,120,180) odgovara izdržljivost od 30,60,90,120,180 minuta.



Slika 5. Izgled profila (4.40m) koji se koristi za ispitivanje

2.5.2 PROVEDBA ISPITIVANJA

1. Pokusni primjerci smiju se ispitivati tek nakon što se postigne čvrstoća s kojom je napravljen statički proračun i kad izgube vlagu.
2. Tijekom postupka sušenja primjerci se moraju vagati sve dok njihova masa ne ostane nepromijenjena u pet uzastopnih dana
3. Ispituju se oni primjerci koje služba ispitivanja navede kao najnepovoljnije
4. Kod nesimetričnih građevinskih elemenata potrebno je izložiti najnepovoljniju stranu, a u dvojbenom slučaju ispitivanje obaviti uz izlaganje sa objiju strana.
5. Nosive građevinske elemente treba ispitati pod opterećenjem i tako ugraditi u ispitni uređaj da se mogu deformirati prema zahtjevima statičkog sustava.
6. Opterećenje treba tako riješiti da ono ostane postojano tijekom ispitivanja i da ne utječe na povećanje temperature u pokusnim primjercima
7. Opterećenje treba tako odmjeriti da nosivi dijelovi strukture u pravilu podnose naprezanja.
8. Kod opterećenja elemenata treba deformacije mjeriti na najnepovoljnijim mjestima
9. U našem pokusu na grede duljine 4.40m opterećenje od 24,5 Tm raspoređeno je na dva mjesta (12,4+12,4Tm)

10. Komora:

- temperatura zraka u ispitnom prostoru peći ne smije najmanje 24 sata prije ispitivanja pasti ispod 15°C niti porasti preko 25°C
- pokusni primjerak treba unutar tog razdoblja postići svoju ravnotežnu temperaturu i ona mora također ležati u navedenom području
- požar u prostoru podržava se pomoću ulja za loženje EL prema DIN-u 51603-1 ili dieselskim gorivom prema DIN-u 51601



Slika 6. Snimka profila, zaštićen Hensothermom 3KS nakon 30 minuta (temperatura je viša od 600° C)

11. Gašenje: prigodom pokusa gašenja vodom, ispitni primjerak treba neposredno nakon požarnog ispitivanja, tijekom 1 minute izložiti naprezanju koje uzrokuje mlaz vode za gašenje. Mlaz vode treba sa udaljenosti od 3 m po mogućnosti pod pravim kutom, tako usmjeriti na ispitni primjerak da obloga bude ravnomjerno izložena naprezanju. Prije tog pokusa ispitni se primjerak smije rasteretiti.



Slika 7. Izgled čeličnih profila nakon hlađenja

Na slici 7. jasno se vide posljedice požara. Premaz je ekspandirao u krutu masu koja se vrlo lako mehanički odvaja ili čisti sa čeličnih profila. Prilikom otklanjanja premaza nisu utvrđena termička oštećenja kao ni deformacije koje bi izazvala izrazito visoka temperatura ($\geq 900^{\circ}\text{C}$). Sanacija se vrši novim premazivanjem i dalje se čelični nosivi profil može koristiti.

12. Izdavanje potvrde: potrebno je napisati potvrdu o provedbi ispitivanja i njegovim rezultatima. Potvrde vrijede najviše pet godina, ali im se na zahtjev može produljiti valjanost.

U potvrdi treba naglasiti:

- broj provedenih ispitivanja
- podatak o stranama ispitanih tijela koje su bile izložene požaru
- dimenzije elemenata, opterećenje i usporedba stvarno nastalih i dopuštenih naprezanja na presjecima
- vrste opterećenja
- položaj mjernih točaka i količina termoelemenata

- upotrijebljeno gorivo
- tlak u ispitnom uređaju
- temperature okolnog zraka prije i za vrijeme požarnog ispitivanja; kod ispitnih uređaja na otvorenome: vremenske prilike
- reakciju izazvanu gašenjem; vrstu i opseg razaranja
- zapažanja o razvijanju dima i plinova tokom požara
- opis elementa nakon provedenog pokusa; izgled, razorenost, nagorenost, preostala debljina
- odrediti razred otpornosti; na osnovu gore navedenih natuknica odrediti razred otpornosti koji pripisuje norma koja je korištena u pokusu-DIN 4102-2

2.6 METODE ISPITIVANJA DEBLJINA NANOSA BOJA NEDESTRUKTIVNIM METODAMA

U današnje doba kada je konkurencija izrazito velika i zahtjevi tržišta za visokom kvalitetom uz nisku cijenu proizvoda sve veći, jedino potpuna kontrola nad određenim procesom može nam garantirati uspjeh. To je ujedno i garancija za uspješnost našeg proizvoda.

Npr. u slučaju prevlačenja određenih materijala različitim premazima koje propisuje proizvođač u certifikatu, mora se garantirati zaštita (protupožarna, antikorozivna) za minimalno određeno vrijeme.

Sve višu kvalitetu, a time i postizanje konkurentnosti na tržištu postizemo potpunom kontrolom procesa, a to se ostvaruje stalnim provjerama i usavršavanjem procesa.

Pod potpunom kontrolom nad procesom podrazumijevamo: sigurnu zaštitu konstrukcije u određenom razdoblju, stabilnost procesa (centriranost; što manje škarta), ali i u ekonomskom smislu (spriječiti nepotrebno trošenje sredstava).

Kontrola premaza postiže se različitim metodama mjerenja. Izdvajaju se destruktivne (dugotrajne i skupe, te dolazi do fizičkog uništenja uzorka; rijetko se koriste) i nedestruktivne metode.

U ovoj točki pobliže će se opisati nedestruktivne metode, a ponajviše magnetska i metoda vrtložnih struja, jer se one zbog svoje jednostavne primjene i niske cijene najviše koriste.

U provedbi konkretnih mjerenja protupožarnog premaza na objektu „Euroherca“ koristili smo uređaj ELCOMETER koji koristi metodu vrtložnih struja (nedestruktivnu metodu). Šira razrada metode provest će se u daljnjem tekstu.

2.6.1 NEDESTRUKTIVNE METODE

U procesu mjerenja ne mogu se mijenjati karakteristična svojstva prevlake i osnovnog materijala. Ona su posljedica tehnologije izrade. Osim toga, ako se pravilno koristi uređaj (prema uputama proizvođača) i pri tome se redovito održava i umjerava od strane ovlaštene mjeriteljske službe, bitno se ne može povećati točnost postupka mjerenja i ona će se kretati u području granične pogreške koju deklarira proizvođač. Podešavanje instrumenata radnim etalonima debljine prevlake ima odlučujuću ulogu u cilju održavanja mjerne obnovljivosti na području mjerenja debljina tankih prevlaka, a time i mjernog jedinstva.

U praksi susrećemo dva osnovna tipa etalona debljine prevlake:

- ETALON FOLIJA (predstavnik nemagnetskih i nevodljivih prevlaka)
- ETALON PLOČICA (s tipičnom kombinacijom prevlake na osnovnom materijalu)

Etalon folijom mjerno jedinstvo, a time i obnovljivost mjerenja je relativno jednostavno održati zbog jednostavnog postupka umjeravanja.

Kod *etalon pločice* postupak umjeravanja se znatno komplicira jer točnost i preciznost mjerenja direktno ovisi, zbog fizikalnih principa mjerenja, o svojstvima etalon pločice. Upravo zbog toga umjeravanje pločica od strane mjeriteljske službe mora biti osigurano tako da je mjerenje prevlake neovisno o sastavu i vrsti prevlake, sastavu i vrsti osnovnog materijala, njihovim svojstvima i tehnologiji nanošenja.

Osnovna netočnost koja može nastati u postupku umjeravanja uređaja sa radnim etalonom prevlake može biti uzrokovana sa dva aspekta:

- ako se koristi radni etalon prevlaka koji ne osigurava mjernu obnovljivost s obzirom na ispitivani uzorak
- ako je na etalonu deklarirana debljina prevlaka koja ne odgovara stvarnoj

2.6.2 POTREBNI UVIJETI ZA OSIGURANJE MJERNE OBNOVLJIVOSTI KOD ETALON PLOČICE

OSNOVNI MATERIJAL:

- istih svojstava (osnovno svojstvo-atomski broj, gustoća, provodljivost, magnetsko svojstvo)
- ista debljina ukoliko je manja od kritične

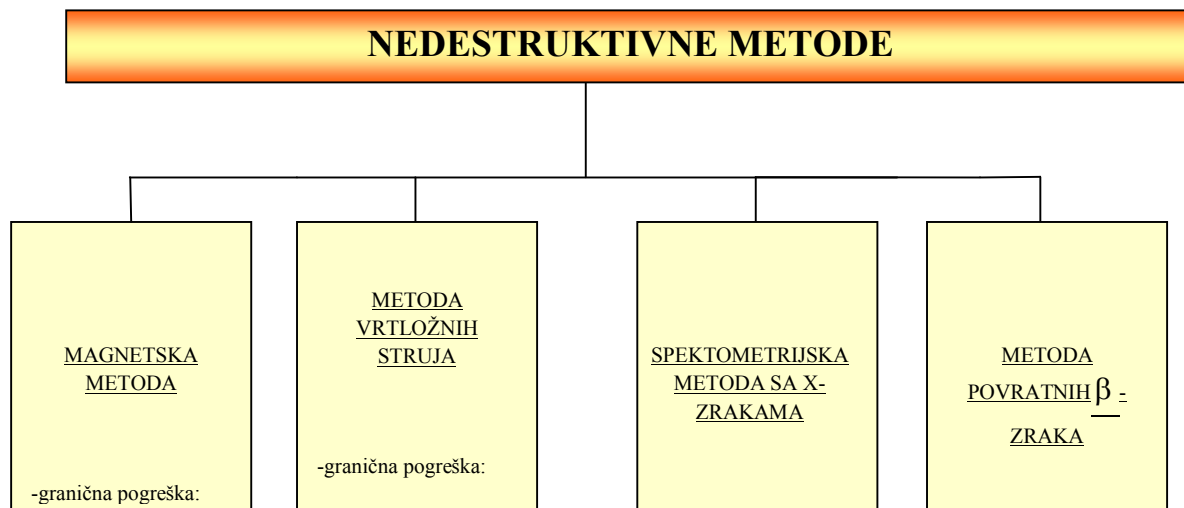
PREVLAKA:

- istih svojstava (osnovno svojstvo-atomski broj, gustoća, provodljivost)
- približno ista debljina

STANJE POVRŠINE:

- isti oblik i veličina, zakrivljenost, hrapavost

2.6.3 PODJELA NEDESTRUKTIVNIH METODA



Slika 8. Podjela nedestruktivnih metoda

2.6.4 MJERENJE DEBLJINE PREMAZA POMOĆU INSTRUMENTA „MIKROTEST“; MAGNETSKA METODA

Instrument pod općim nazivom „MIKROTEST“ vrlo je jeftin i najjednostavniji instrument za mjerenje debljine premaza. Mjerenje se zasniva na fizikalnom svojstvu magnetizma čelika odnosno željeza te se ova metoda popularno naziva magnetska metoda mjerenja.

Instrument radi na principu magnetskog privlačenja između stalnog odnosno permanentnog magneta i osnovnog metala. Ovom metodom mjere se isključivo ne magnetski premazi kao što su boje, lakovi, plastični materijali, guma i emajl na magnetskoj podlozi (čelik, željezo) ili magnetske prevlake (npr. Ni) na nemagnetskoj podlozi kao što je mesing, bakar i slično.

Magnetska metoda zasniva se na zakonima magnetizma, gdje se magnetski tok zatvara preko predmeta (osnovnog materijala) i premaza čija debljina se mjeri. Ne magnetska prevlaka svojom debljinom smanjuje međusobnu silu privlačenja između magnetne sonde i osnovnog materijala. Detektira se sila privlačenja između sonde i osnovnog materijala, te se mjeri sila odvajanja. Odvajanje se ostvaruje preko spiralne opruge. Vrijednost na skali je ustvari neka postignuta sila odvajanja preko opruge koja služi kao posrednik, a pretvorena je u vrijednost debljine premaza.

Bitno je napomenuti da se za točno mjerenje instrument podešava pomoću etalon folija. To su plastični listići jednolike i točno određene debljine. Isporučuju se uz sam instrument ili se naručuju u ovlaštenoj ustanovi koja obavlja umjeravanje etalon folija. Dobro je imati nekoliko setova folija za podešavanje i provjeru samog instrumenta. Bitno je da se podešavanje izvede na onom materijalu na kojem se mjeri debljina premaza. To znači da se prije procesa nanošenja premaza na „golom“ osnovnom materijalu mora obaviti podešenje samog instrumenta.

Prednost: jeftin instrument

Nedostatak: mjerenja se moraju obaviti na ravnim i horizontalno položenim površinama, paziti da instrument ne dođe u blizinu izmjeničnih magnetskih polja zbog mehaničke i fizičke osjetljivosti trajnog magneta

2.6.5 MJERENJE DEBLJINE PREMAZA POMOĆU INSTRUMENTA „ELCOMETER“

Elcometer (slika 9.) je elektronički instrument za nerazorno mjerenje debljine zaštitnih premaza. On omogućava precizno i točno, direktno mjerenje nevodljivih premaza kao što su boje, lakovi, plastični i slični premazi na čeličnoj podlozi kao osnovnom materijalu. U praksi se susreće puno kombinacija prevlaka i osnovnih materijala, a s tim instrumentom je moguće gotovo sve njih izmjeriti.



Slika 9. Elcometer 456

Elcometer funkcionira induciranjem vrtložnih struja u metalnim površinama. Vrtložne struje su slabe izmjenične struje koje kratkotrajno teku u zatvorenome putu u površinskom sloju vodljivog materijala. Takve struje se induciraju pomoću mjerne sonde koju dovedemo u dodir sa površinom premaza, a sonda i mjerni elektronički sistem daju energiju određene frekvencije. Dubina prodiranja vrtložne struje prvenstveno zavisi od:

- električne provodljivosti metala u kojem teče vrtložna struja
- električne frekvencije vrtložne struje inducirane pomoću mjerne sonde


Ova dva navedena faktora određuju dubinu prodiranja vrtložnih struja, a time određuju i maksimalno područje mjerenja debljine sloja premaza na određeni materijal ili kombinaciju materijala. Frekvencije koje se koriste u praksi: 100 kHz, 500 kHz, 2000 kHz, 6000kHz.

Utvrđeno je da se povećanjem frekvencije smanjuje dubina prodiranja vrtložnih struja u osnovni materijal.

2.6.5.1 PONAŠANJE MJERNE SONDE KADA NA ČELIKU POSTOJI NEVODLJIVI PREMAZ

Sonda je tada odijeljena od vodljivog osnovnog materijala (čelik) sa iznosom debljine premaza. Kao rezultat, intenzitet reakcije vrtložnih struja pada tako da stvara privid da materijal ima manju provodljivost. Ako se debljina prevlake poveća, prividna provodljivost osnovnog materijala nastavlja se smanjivati.

Na slici 10. mogu se vidjeti različita očitavanja na zaslonu uređaja Elcometer za određenu debljinu premaza pružajući mogućnost mjerenja nevodljivih premaza kao što su boje, lakovi...



Slika 10. Prodiranje vrtložnih struja kod različitih debljina premaza

2.6.5.2 PODEŠAVANJE UREĐAJA „ELCOMETER“

Ovaj dio je izrazito važan za samog operatera sa stanovišta točnosti i pouzdanosti mjerenja, te ga je potrebno savladati i razumjeti.

Zbog različitih kemijskih sastava čelika, stanja završne toplinske obrade i površinske hrapavosti razlikuju se fizikalna svojstva pa tako i specifična vodljivost koja je različita od materijala do materijala.

Upravo iz tih razloga potrebno je instrument podesiti pomoću etalonskih folija debljine i provjeriti „nulu“ na onom materijalu na kojem je nanescena debljina premaza. Postupak je potrebno izvršiti u skladu sa uputama za rad instrumentom. Nakon podešavanja instrument bi u toku mjerenja morao uspoređivati unesene debljine pomoću folije, debljinu premaza metodom prodiranja vrtložnih struja. Raspon bi se trebao kretati između namještene „nule“, dobivene na samom „golom“ osnovnom materijalu i debljine etalon folije.

2.6.5.3 PREDNOSTI UREĐAJA ELCOMETER

- mjerenje se obavlja trenutno kratkotrajnim pritiskom mjerne sonde preko vodilice i opruge na mjernu površinu premaza (Slika 11.)
- mjerenje je moguće u svim položajima i to bez napora; (vertikalne površine, površine iznad glave)
- mjerenje je moguće izvesti i u slabo vidljivom prostoru jer uređaj sprema podatke u memoriju instrumenta
- uređaj odmah izračunava potrebne vrijednosti: srednju vrijednost, standardnu devijaciju, odmah određuje minimalnu i maksimalnu vrijednost
- sve gore navedene vrijednosti mogu se direktno pohraniti u računalo



Slika 11. Rukovanje Elcometrom


3. TEORIJSKA RAZRADA SPOSOBNOSTI PROCESA

3.1 STATISTIČKA KONTROLA PROCESA

Statistička kontrola procesa podrazumijeva uporabu statističkih metoda za identifikaciju postojanja sistemskih uzroka varijacija u procesu.

Osnovno pravilo statističke kontrole procesa govori da se varijacije slučajnih uzroka trebaju prepustiti slučaju, dok se sistemske varijacije trebaju identificirati i eliminirati.

Osnovni koncept statističke kontrole procesa polazi od pretpostavke da se svaki mjerljivi fenomen može izraziti statističkom distribucijom. Odnosno, promatrani set podataka tvori uzorak efekata nepoznatih uobičajenih uzoraka. Iz toga proizlazi, da nakon što se određenim postupcima učini sve kao bi se uklonio uzrok sistemskih varijacija u nekom procesu, još uvijek ostaje određen iznos varijabilnosti prikazan u stanju kontrole [5].




Slika 12. Slučajne, sistemske varijacije i veza sa distribucijom

Postoje tri osnovne značajke distribucija:

- Lokacija
- Širina
- Oblik

Svaka distribucija može se opisati sa ova tri parametra. Lokacija se odnosi na tipične vrijednosti distribucije, širina distribucije je iznos za koji se manje vrijednosti razlikuju od većih, dok oblik distribucije govori o izgledu distribucije (pravokutan, zvonolik itd.).



Slika 13. Načini varijacija distribucija

3.1.1 CENTRALNI GRANIČNI TEOREM

Centralni granični teorem govori da se bez obzira na oblik distribucije populacije ili događaja koji se prate, distribucija prosječnih vrijednosti uzoraka iz te iste populacije ili događaja će imati tendenciju poprimiti oblik normalne distribucije kako raste veličina uzorka.

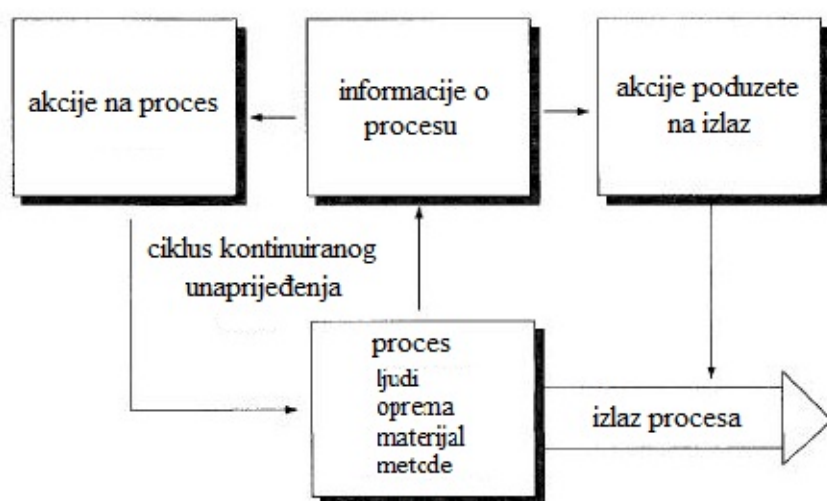
Centralni granični teorem ima širok spektar primjene, te bi bez njega bilo potrebno razviti zasebni statistički model za svaku nenormalnu distribuciju koju susrećemo u praksi.

Zbog centralnog graničnog teorema možemo koristiti prosječne vrijednosti malih uzoraka za vrednovanje bilo kojeg procesa pomoću normalne distribucije, te je temelj dijela kontrole kvalitete koji se bavi kontrolnim kartama.

Bez statističke kontrole procesa temelj za odluke vezane uz poboljšavanje kvalitete temeljili bi se na intuiciji i inspekciji nakon što bi proizvod bio u potpunosti proizveden. Statistička kontrola procesa pruža znanstvene osnove za odluke vezane za poboljšanje procesa.

3.1.2 PREVENCIJA PROTIV OTKRIVANJA

Sustav kontrole procesa možemo smatrati sustavom povratnih informacija koji povezuje izlaz procesa sa ulazom. Postoje četiri glavna elementa koji su uključeni u sustav: sam proces, informacije o procesu, akcije na proces i akcije poduzete na izlaz.



Slika 14. Sustav kontrole procesa

Pod procesom podrazumijeva se cjelokupna kombinacija ljudi, opreme, ulaznih materijala, metoda i okoliša koji zajedno stvaraju izlaz. Informacije o performansama se dobivaju iz evaluacije izlaza procesa. Izlaz procesa uključuje više od proizvoda, sadrži informacije o procesu kao što je temperatura, vrijeme ciklusa i itd. Akcije poduzete na proces orijentirane su na budućnost u smislu da će utjecati na izlaz procesa [5].


3.1.3 SLUČAJNI I SISTEMSKI UZROCI VARIJACIJA

Kao što smo već ranije napomenuli, statistička kontrola procesa definirana je kao korištenje analitičkih statističkih metoda za identifikaciju postojanja sistemskih uzroka varijacija u procesu.

Osnovno pravilo statističke kontrole procesa govori da se varijacije slučajnih uzroka trebaju prepustiti slučaju, dok se uzroci sistemskih varijacija trebaju pronaći i eliminirati.

Međutim, ovo pravilo koje je ustanovio Shewart, ne bi smjelo biti krivo protumačeno u smisli da se slučajne varijacije trebaju ignorirati. Naprotiv, također im treba posvetiti pažnju jer upravo „long term“ poboljšanje procesa leži u smanjivanju slučajnih varijacija.

Slikom 18. Tipovi varijacija dan je prikaz prirode varijacije u kontrolnim kartama i naznačena su područja koja pripadaju slučajnim, a koja sistemskim varijacijama u kontrolnim kartama.



Slika 15. Tipovi varijacija procesa

Varijacije između dvije kontrolne granice (gornje i donje) smatraju se slučajnima. Za bilo koju varijabilnost koja se nađe izvan tih granica, smatra se da je došla iz sistemskih uzroka.

Potrebno je naglasiti da se kontrolne granice ne postavljaju proizvoljno, nego se računaju iz stvarnih podataka korištenjem statističkih metoda.

Možemo zaključiti da bi bez statističkih metoda bilo praktički nemoguće utvrditi prirodu varijabilnosti u procesu.

3.2 KONTROLNE KARTE

Kontrolne karte su također poznate pod imenom Shewart karte, te se u statističkoj kontroli procesa koriste za određivanje da li se proces nalazi u stanju statističke kontrole.

Ako analiza kontrolnih karata pokazuje da je proces trenutno pod kontrolom, tada se podaci prikupljeni iz procesa mogu koristiti za daljnje predviđanje ponašanja procesa. Ukoliko kontrolne karte pokazuju da proces nije pod kontrolom, analiza kontrolnih karata može pomoći u otkrivanju uzroka varijacije koji treba ukloniti kako bi se proces stavio pod kontrolu.

Kontrolne karte mogu se promatrati kao dio objektivnog i discipliniranog pristupa koji omogućava ispravne odluke u pogledu kontrolne procesa, uključujući donošenje odluka o promjeni parametara procesa.

Zasluge za dizajn i primjenu kontrolnih karata pripadaju Walteru A. Shewart-u koji je bio zaposlenik Bell Telephone Company. Inženjeri tvrtke bili su u potrazi kako poboljšati pouzdanost telefonskih sustava, te su došli do zaključka kako je potrebno smanjiti varijacije u samom proizvodnom procesu. Shewart je internim memorandumom predstavio kontrolne karte kao sredstvo uklanjanja varijacija koje je podijelio prema uzroku nastajanja: zajedničke i posebne. Taj memorandum sadržavao je sva bitna načela i razmatranja koje danas znamo pod zajedničkim terminom kontrola kvalitete.

Razlikujemo dvije osnovne vrste kontrolnih karata:

- Kontrolne karte za mjerljive karakteristike koje su temeljene na normalnoj distribuciji (upotrebljavaju se za kontinuirane podatke kao što su rezultati mjerenja): \bar{x} – Rkarta, \bar{x} – skarta, \bar{x} – M Rkarta, $C u S u$ karta, $E W M$ karta.
- kontrolne karte za atributivne karakteristike koje su temeljene na binomnoj i Poissonovoj distribuciji: p karta, $n p$ karta, c karta, u karta.

Kod primjene kontrolnih karata u statističkoj kontroli kvalitete procesa aritmetička sredina, standardna devijacija, raspon su statistički najupotrebljiviji pojmovi koji se koriste za analizu prikupljenih podataka. Točka koja je izašla iz kontrolnog područja koje smatramo da zadovoljava određene karakteristike je indikator da je prisutan poseban uzrok varijacije i da je potrebno provesti niz postupaka kojima će se utvrditi uzrok te varijacije.

Ciljevi primjene kontrolnih karata su slijedeći:

- dovođenje procesa u stanje statističke kontrole
- utvrđivanje trendova i pomaka procesa u cilju zaštite od neželjenih rezultata
- utvrđivanje potreba za remontom ili nabavom nove opreme elemenata procesa i sl.
- dobivanje svih saznanja o mogućnostima poboljšavanja procesa i mogućnostima postizanja zahtijevane kvalitete proizvoda (procjenjivanje sposobnosti procesa) [6]

Svrha kontrolnih karata je omogućiti jednostavno otkrivanje događaja koje indiciraju stvarne promjene u procesu.

Kontrolne karte uobičajeno se sastoje od slijedećih značajki:

- mjerene karakteristika koje predstavljaju kvalitetu u uzorcima (podaci)
- srednjih vrijednosti statističkih karakteristika iz prikupljenih uzoraka
- središnje linije procesa (central line CL) koja predstavlja liniju aritmetičke sredine statističkog parametra koji se prati kontrolnom kartom
- kontrolnih granica koje predstavljaju statističke granice i nisu povezane sa granicom specifikacije (zahtjeva). Kontrolne granice se računaju na granice rasipanja ($\pm 3\sigma$) statističkog parametra koji se prati kontrolnom kartom. Također se uz kontrolne granice mogu koristiti i granice upozorenja postavljene na $\pm 2\sigma$ ili $\pm 1\sigma$. Podatak izvan kontrolnih granica ukazuje na značajan uzrok varijacije u procesu.

3.2.1 \bar{x} -R KARTA

U statističkoj kontroli kvalitete je vrsta kontrolne karte koja daje uvid u kretanje procesa na osnovi dva važna pokazatelja procesa:

- kretanja aritmetičkih sredina uzoraka \bar{x}_i koji daje uvid u centriranost procesa
- kretanja raspona uzoraka R_i koji govori o rasipanju procesa

\bar{x} -R kontrolne karte se koriste u slijedećim situacijama:

- veličina uzorka je relativno mala ($n=2$ do 10)
- veličina uzorka je konstantna

Postoje 3 moguća načina postavljanja kontrolnih granica za \bar{x} -R kontrolne karte:

- praćenjem nepoznatog procesa u cilju ustanovljavanja njegovih prirodnih mogućnosti u pogledu centriranosti i rasipanja
- na temelju poznatih prošlih podataka o procesu
- na temelju unaprijed zadanih tolerancija

Kontrolne granice na temelju praćenja nepoznatog procesa

a) kontrolne granice za kretanje aritmetičkih sredina uzoraka

$$G_{\bar{x}} = \bar{x} \pm 3\sigma_{\bar{x}} = \bar{x} \pm 3\frac{\sigma_s}{\sqrt{n}} \quad (3.1)$$

Budući da je:

$$\sigma_s = \frac{\bar{R}}{d_2},$$
$$\bar{R} = \frac{\sum R_i}{k} \quad (3.2)$$

Gdje je k broj obilazaka kontrolora, odnosno broj uzetih uzoraka, dobiva se:

$$G_{\bar{x}} = \bar{x} \pm 3 \frac{\bar{R}}{d_2 \sqrt{n}} \quad (3.3)$$

Označi li se $\frac{\bar{R}}{d_2 \sqrt{n}}$ s koeficijentom A_2 , koji je isključivo funkcija veličine uzorka n , konačno se dobiva:

$$G_{\bar{x}} = \bar{x} \pm A_2 \bar{R} \quad (3.4)$$

b) kontrolne granice za kretanje raspona uzoraka

Iz pojedinačnih raspona R_i dobiva se prosječni raspon:

$$\bar{R} = \frac{\sum R_i}{k} \quad (3.5)$$

Kontrolne granice se u ovim slučajevima postavljaju na udaljenost od tri standardne devijacije, pa slijedi:

$$G_R = \bar{R} \pm 3\sigma_R = \bar{R} \pm 3b_2\sigma_{ST} = \bar{R} \pm 3b_2 \frac{\bar{R}}{d_2} = (1 \pm \frac{3b_2}{d_2})\bar{R} \quad (3.6)$$

Označi li se $1 + \frac{3b_2}{d_2}$ sa D_4 , a $1 - \frac{3b_2}{d_2}$ sa D_3 , dobivaju se kontrolne granice:

$$G_R = D_4 \bar{R}, \quad D_R = D_3 \bar{R} \quad (3.7)$$

Ukoliko je vrijednost \bar{x} ili R bilo kojeg uzorka izvan proračunatih kontrolnih granica potrebno je izvršiti korekciju. Korekcija se vrši na način da se zanemari kompletni uzorak čija je vrijednost \bar{x} ili R izašla izvan kontrolnih granica. Potom se vrši proračun novih kontrolnih granica bez rezultata tog uzorka. Tim postupkom se otklanjaju značajni uzroci varijacija.

Tablica 1. Koeficijenti kontrolnih granica za \bar{x} -R kontrolnu kartu

n	A ₂	D ₃	D ₄	d ₂
2	1,880	0	3,267	1,128
3	1,023	0	2,575	1,693
4	0,729	0	2,282	2,059
5	0,577	0	2,115	2,326
6	0,483	0	2,004	2,534
7	0,419	0,076	1,924	2,704
8	0,373	0,136	1,864	2,847
9	0,337	0,184	1,816	2,970
10	0,308	0,223	1,777	3,078

3.2.2 \bar{x} -S KARTA

U statističkoj kontroli kvalitete \bar{x} -s karta je vrsta kontrolne karte koja daje uvid u kretanje procesa na osnovi dva važna pokazatelja procesa:

- centriranost preko kretanja aritmetičkih sredina uzoraka
- rasipanje preko standardnih devijacija

\bar{x} -s karte su konceptualno jednake \bar{x} -R kartama. Razlika je u tome da se standardna devijacija uzoraka koristi za mjerenje disperzije, a ne raspona uzoraka. Standardna devijacija uzorka je statistički učinkovitija od raspona uzoraka za veličine uzoraka većih od 2. Ta učinkovitost raste sa veličinom uzorka.

Postoje 2 moguća načina postavljanja kontrolnih granica za \bar{x} -s kontrolne karte:

- kontrolne granice za kretanje aritmetičkih uzoraka
- kontrolne granice za kretanje standardnih odstupanja uzoraka

Ova vrsta kontrolnih karata primjenjuje se u procesima koji su zaokruženog tipa i odvijaju se u zatvorenim ciklusima određene duljine trajanja, kada se proces ne može pratiti dok je ciklus u tijeku, nego se na kraju ciklusa na temelju uzoraka donose zaključci o procesu [6].

Postavljanje kontrolnih granica za kretanje aritmetičkih sredina uzoraka:

$${}^G_D K \ G_{\bar{x}} = \bar{x} \pm 3\sigma_{\bar{x}} = \bar{x} \pm 3 \frac{\sigma_{S \ T}}{\sqrt{n}} \quad (3.8)$$

Budući da je s^- aritmetička sredina standardnih odstupanja svih uzoraka:

$$s^- = \bar{s} \sigma_{S \ T} \quad (3.9)$$

Dobiva se:

$${}^G_D K \ G_{\bar{x}} = \bar{x} \pm 3\sigma_{\bar{x}} = \bar{x} \pm 3 \frac{s^-}{c_2 \sqrt{n}} \quad (3.10)$$

Ako se $\frac{3}{c_2 \sqrt{n}}$ označi koeficijentom A_1 koji je funkcija veličine uzorka dobije se:

$${}^G_D K \ G_{\bar{x}} = \bar{x} \pm A_1 s^- \quad (3.11)$$

Kontrolne granice za kretanje standardnih odstupanja uzoraka:

$${}^G_D K \ G_s = s^- \pm 3\sigma_{s^-} = s^- \pm 3\sigma_{S \ T} \quad (3.12)$$

Budući da je:

$$s^- = \bar{s} \sigma_{S \ T} \quad (3.13)$$

Dobiva se:

$${}^G_D K \ G_s = s^- \left(1 \pm \frac{3a_2}{c_2} \right) \quad (3.14)$$

Ukoliko se $1 \pm \frac{3 \sigma}{c_2}$ označi sa B_4 , a $1 \pm \frac{3 \sigma}{c_2}$ sa B_3 dobivaju se kontrolne granice:

$$G K \bar{X} = B_4 \bar{X}$$

$$D K \bar{X} = B_3 \bar{X}$$

(3.15)

Tablica 2. Koeficijenti kontrolnih granica za \bar{X} -S kontrolnu kartu

n	A ₁	B ₃	B ₄	c ₂
10	1,028	0,284	1,716	0,9227
15	0,816	0,428	1,572	0,9400
20	0,697	0,510	1,490	0,9619
25	0,619	0,565	1,435	0,9696
30	0,562	0,603	1,397	0,9748
35	0,518	0,633	1,367	0,9784
40	0,483	0,658	1,342	0,9811
45	0,455	0,678	1,322	0,9832
50	0,431	0,695	1,305	0,9849
60	0,392	0,723	1,227	0,9874
70	0,363	0,744	1,256	0,9892

3.3 NORMALNA DISTRIBUCIJA I TESTIRANJE HIPOTEZA

Izraz normalitet distribucije označava i proces i rezultat provjere odstupanja li neka konkretno dobivena distribucija statistički značajno od normalne distribucije. Provjera se, u načelu, provodi tako da se usporede ili stvarno dobivene frekvencije koje čine dobivenu distribuciju, s frekvencijama koje bi bile u skladu s normalnom distribucijom ili usporedbom odabranih površina normalne distribucije i stvarno dobivene distribucije. Površine standardizirane normalne distribucije također je moguće odrediti s pomoću tablica normalne distribucije.

Prije provođenja analize podataka korištenjem normalne distribucije, potrebno je provjeriti da li su podaci koji se proučavaju normalno distribuirani. Ako uzimamo nenormalne podatke kao da su normalni, rezultati analize će biti pogrešni interpretirani.

Danas su dostupni mnogi programski alati koji omogućuju provođenje statističke analize podataka. Jedan od takvih alata je Minitab koji će biti korišten tijekom izrade ovog rada. Minitab nudi opcije testiranja normaliteta podataka pomoću tri osnovna testa normaliteta:

- Anderson-Darling
- Ryan-Joyner
- Kolmogorov-Smirnov

Svi ovi testovi daju isti rezultat i svi se temelje na testiranju hipoteza. Nulta hipoteza pretpostavlja da podaci slijede normalnu razdiobu, a alternativna hipoteza pretpostavlja da podaci ne slijede normalnu razdiobu.

3.3.1 ANALIZA SPOSOBNOSTI PROCESA SA NENORMALIZIRANIM PODACIMA

U kontroli kvalitete jedno od važnijih područja je analiza sposobnosti procesa. Jedna od mogućnosti procjene sposobnosti je korištenje Z transformacije uz uvjet da su podaci normalno distribuirani.

Pomoću Z transformacije dobivamo podatke koji su nužni za utvrđivanje sposobnosti procesa (C_{pk} -potencijala sposobnost procesa, P_{pk} -preliminarna sposobnost procesa).

Međutim nisu svi procesi normalno distribuirani, što ne znači da su pogrešni. Imamo dosta primjera oko nas koji to pokazuju. Primjerice u distribucijskim centrima gdje zaposlenici pakiraju i otpremaju proizvode ukupna pogreška nije normalno distribuirana jer ovisi o mnogo faktora, poput osposobljenosti, raspoloženja pojedinog zaposlenika, o standardnim procedurama itd..

Budući da se podaci ne moraju nužno pokoravati normalnoj distribuciji postoji nekoliko načina postupanja s takvim podacima:

- Ako su podaci u podskupovima normalni, sposobnost cjelokupnog procesa može se procijeniti iz sposobnosti podskupova
- Ako se podaci ne pokoravaju normalnoj razdiobi, a može se izvršiti njihova normalizacija potrebno je obaviti taj postupak prije analize
- Upotreba drugih distribucija (Weibull, log-normalna)

3.3.2 NORMALIZACIJA PODATAKA

Ako analizirani podaci odstupaju od normalne distribucije, a alati koje se rabe za analizu zahtijevaju da se ti isti podaci pokoravaju normalnoj distribuciji, potrebno ih je normalizirati.

Taj postupak može se provesti slijedećim postupcima:

- Box-Cox transformacija
- Johnson transformacija
- Normalizacija prirodnim algoritmom

3.4 PRIMJER

Pretpostavimo da radimo za tvrtku koja proizvodi podne pločice, te želimo kontrolirati savijanje pločica. Kako bi se osigurala kvaliteta proizvodnje, izvršava se mjerenje savijanja na 10 pločica svaki radni dan u 10 dana. Rezultati savijanja su dani u tablici.

Tablica 3. Rezultati mjerenja savijanja pločica

Rezultati mjerenja (mm)									
1,60103	2,31426	0,52829	2,8953	0,44426	5,3123	1,22095	4,24464	1,12465	0,28186
0,84326	2,55635	1,01497	2,86853	2,48648	1,92282	6,32858	3,21267	0,78193	0,57069
3,00679	4,72347	1,12573	2,18607	3,91413	1,22586	3,80076	3,48115	4,14333	0,70532
1,29923	1,75362	2,56891	1,05339	2,28159	0,76149	4,22622	6,66919	5,30071	2,84843
2,24237	1,62502	4,23217	1,2556	0,96705	2,3993	4,33233	2,44223	3,79701	6,25825
2,63579	5,63857	1,34943	1,97268	4,98517	4,96089	0,42845	3,51246	3,2477	3,37523
0,34093	4,64351	2,84684	0,84401	5,79428	1,96775	1,2041	8,03245	5,04867	3,23538
6,96534	3,95409	0,76492	3,32894	2,52868	1,35006	3,44007	1,13819	3,068	6,08121
3,46645	4,38904	2,78092	4,15431	3,08283	4,79076	2,51274	4,27913	2,45252	1,66735
1,41079	3,24065	0,63771	2,57873	3,82585	2,20538	8,09064	2,05914	4,69474	2,12262

Primjer je razrađen u tri faze. Kroz razradu praktičnog zadatka dan je uvid u teoriju transformacija nenormalnih podataka u normalne, te je ujedno razrađeno praktično rješenje zadanog problema računalnim alatom Minitab.

U prvoj fazi će se ispitati priroda ponašanja podataka. Ispitivanje se vrši preko funkcije „probability plot“ iz kojeg zaključujemo pomoću p- vrijednosti i AD (Anderson – Darling) kako se podaci ponašaju. Cjelokupni pregled teorije o p- vrijednosti i AD dan je u nastavku rada. Zaključci o tim podacima se mogu izvršiti preko p- vrijednosti i AD. Ukoliko se podaci ne ponašaju normalno, provest će se Box-Cox transformacija koja je također detaljno definirana. Druga faza obuhvaća detaljnu razradu sposobnosti procesa. Preko primjera će se nastojati pokazati kako osposobiti proces i kako ga još poboljšati (Taguchi). Treća faza daje prikaz procesa u Weibull-ovoj i Lognormalnoj distribuciji.

3.5 PRVA FAZA RAZRADE PRIMJERA

3.5.1 TEORIJSKA RAZRADA P-VRIJEDNOSTI I ANDERSON-DARLING TESTA

3.5.1.1 P-VRIJEDNOST

Određuje primjerenost odbijanja nulte hipoteze u hipotezi testa. Raspon p vrijednosti je od 0 do 1. Što je manja vrijednost p, manja je vjerojatnost da je odbijanje nulte hipoteze pogreška. Prije provođenja bilo kakve analize, potrebno je odrediti α razinu. Uobičajena vrijednost koja se uzima je 0.05. Ako je p- vrijednost prema statističkom testu manji od α , odbacujemo nultu hipotezu. Zbog svoje preko potrebne uloge u testiranju hipoteza, p- vrijednosti se koriste u mnogim područjima statistike, u osnovnoj statistici, linearnim modelima, računanje pouzdanosti i pri multivarijabilnoj analizi, značajno je i pri regresijskoj analizi gdje imamo ovisnost više parametara jedni o drugima. Ključno je razumjeti što nulta i alternativne hipoteze predstavljaju u svakom testu, a zatim pomoću p- vrijednosti odlučiti da li odbijamo nultu hipotezu.

Na primjer, testiramo dva uzorka t-testom gdje testiramo razlike između srednjih čvrstoća čeličnih mlinova na temelju slučajnih uzoraka od svake. U ovom slučaju, nulta hipoteza navodi da razlike među njima ne postoje tj. da su srednje vrijednosti populacija jednake. Alternativne hipoteze tvrde da te vrijednosti nisu jednake. P-vrijednost ispod razine također sugerira da su populacije različite.

P-vrijednost se računa iz promatranog uzorka i predstavlja vjerojatnost pogrešnog odbijanja nulte hipoteze kada je ona stvarno istinita (tip 1 pogreške),

Što je niža p –vrijednost, manje je pogodan rezultat ako je nulta hipoteza istinita, a time je mnogo „značajniji“ rezultat (u statističkom smislu, potrebno je provjeravati proces). Često se odbija nulta hipoteza ako je p-vrijednost manja od 0.05 ili 0.01, što odgovara 5% ili 1 % šanse da postoji mogućnost odbijanja nulte hipoteze kada je istinita (tip pogreške 1) i mogućnost da je nulta hipoteza prihvaćena kada je to netočno (tip pogreške 2).

Nulta hipoteza se odbacuje ako je p vrijednost manja ili jednaka razini značajnosti(α):

$$p \leq \alpha$$

(3.16)

Ako je razina jednaka 0.05 što znači da je samo 5% vjerojatno da će se ostvariti pogrešan rezultat, ako se smatra da je nulta hipoteza istinita. Ako se oni dogode, takvi rezultati se smatraju izvanrednima.

3.5.1.2 RAZINA ZNAČAJNOSTI

U statistici značajan ne znači važan kao u svakodnevnom govoru, već upućuje na razlike koje se mogu dogoditi pri testiranju uzoraka. Te razlike mogu biti primijećene ili ne, ovisi o važnosti testa. Količinu dokaza koju je nužno prihvatiti da je događaj vjerojatno nastao slučajno, poznat je kao kritična razina značajnosti ili p vrijednost.

Poželjno je obje hipoteze (nultu i alternativnu) definirati i istražiti ponavljanje uzrokovanja svojstva postupka i izbjeći mogućnost pojave 1 i 2 pogreške. Razina značajnosti je takva da je vjerojatnost pogrešno procijenjene nulte hipoteze jednaka navedenoj vjerojatnosti.

Razina značajnosti se označava simbolom α . Najčešće korištene razine su 5%(0.05), 1%(0.01) i 0.1%(0.001). ako test značajnosti daje p-vrijednost manju od α razine, nulta hipoteza se odbacuje.

Takvi rezultati se neformalno nazivaju „statistički značajni“ rezultati. Npr. ako netko tvrdi za određeni događaj da postoji samo jedna šansa od tisuću da se on slučajno dogodi. To podrazumijeva 0.001 razinu statističke značajnosti. Što je niža razina značajnosti, potrebni su jači dokazi. Odabir razina značajnosti vrši se proizvoljno, ali za mnoge aplikacije bira se razina od 5%. Ta razina je konvencionalna.


U nekim situacijama prikladnije je izraziti razinu značajnosti kao $1 - \alpha$. Stoga je potrebno pri interpretaciji značajnosti imati na umu što se točno ispituje statistički. Manje α razine povećavaju povjerenje u odlučivanju značenja, ali je povećan rizik odbacivanja nulte hipoteze (tip pogreške 2) ili „lažna negativna odluka“ i tako imaju manje statističke snage.

Izbor α razina neizbježno uključuje kompromis između značenja i snage tj. između 1 tipa pogreške i 2 tipa pogreške. Snažniji eksperiment (oni sa više subjekata; parametara ili ponavljanja) može ukloniti ovaj izbor proizvoljnog stupnja.

U nekim područjima, npr. nuklearna fizika, uobičajeno je izraziti statističku značajnost u jedinicama „ σ “-sigma-standardna devijacija Gaussove distribucije. Statističke značajnosti „ $n \sigma$ “ mogu biti pretvorene u vrijednost α putem uporabe funkcijske pogreške:

$$\alpha = 1 - \text{erf}\left(\frac{n}{\sqrt{2}}\right); \text{erf}(z) = \frac{2}{\sqrt{\pi}} \int_0^z e^{-t^2} dt \quad (3.17)$$

($\text{erf}(z)$ je funkcija pogreške, sastavni dio normalne distribucije, tj. ugrađena u nju)



Slika 16 . Erf funkcija pogreške

Korištenje σ te povezivanje sa statističkom značajnosti, a sve preko normalne razdiobe, često se koristi u mjernim nesigurnostima. Inače ovaj pristup je vrlo koristan za istraživačka područja. Npr. ako teorija predviđa da parametar ima vrijednost 100 i jedna mjera da bude 109 ± 3 , tada se može izvješće mjerenja pisati kao „ 3σ odstupanja“ od teoretskog predviđanja. U odnosu na α , ova izjava je ekvivalent za izjavu: uz pretpostavku da je teorija istinita, vjerojatnost dobivanja slučajnih eksperimentalnih rezultata je 0.27% ($1 - \text{erf}\left(\frac{3}{\sqrt{2}}\right) = 0.0027$).

3.5.1.3 ČESTI NESPORAZUMI

Podaci dobiveni usporedbom p vrijednosti sa razinom značajnosti (α) će voditi jednom od dva rezultata: ili se odbacuje nulta hipoteza ili se nulta hipoteza ne može odbaciti na toj razini značajnosti (što ne znači da je nulta hipoteza istinita).

Mala p-vrijednost koja inicira značajnost dobivenih rezultata ne znači da je alternativna hipoteza točna. Postoje dodatni testovi (AD, KS) koji se mogu izvesti kako bi se više definirala izjava o valjanosti nulte hipoteze.

Unatoč čestoj upotrebi p- testova za statističku značajnost na meti je čestih kritika zbog svojih inherentnih nedostataka i mogućnosti pogrešnog tumačenja.

Postoje nekoliko uobičajnih nesporazuma vezanih uz p-vrijednost:

- P-vrijednost nije vjerojatnost da je nulta hipoteza istinita.(Ovaj lažni zaključak je korišten da opravda „pravilo“ razmatranja rezultata koji su značajniji ako je p-vrijednost mala, blizu 0). Jedan od poznatih pojmova je Jeffreys-Lindley paradoks koji opisuje situaciju u statistici u kojoj Bayesianov, baziran na dokazima koji služe za zaključivanje o vjerojatnosti hipoteze i Frequentist statistic (česti pristupi), zaključci se izvede iz statističkih uzoraka bazirano na testiranju hipoteza i intervalima povjerenja, u problemima testiranja hipoteza daju suprotne rezultate.

Opis paradoksa

Nulta hipoteza H_0 , rezultat eksperimenta x i distribuciju(prior distribution, ona koja se vodi zaključcima) koja ne favorizira H_0 . Paradoks se javlja kada:

1. Rezultat x je značajan kada se zaključci uzimaju iz statističkih uzoraka tj. Po pretpostavci, što znači dovoljno dokaza da se odbaci H_0 na razini od 5%
2. Po Bayesianovoj vjerojatnosti, temeljenoj na dokazima, da x podržava nultu hipotezu, recimo 95% što ukazuje da postoje jaki dokazi da je nulta hipoteza istinita.

Ovakvi rezultati se mogu dogoditi u isto vrijeme na rubovima samih distribucija. S jedne strane imamo H_0 sa vjerojatnosti p a s druge strane distribuciju sa ostatkom površine tj. $1 - p$. Do paradoksa dolazi zbog postavljene granice na samom početku.

- P-vrijednost nije vjerojatnost da je njezin rezultat „samo slučajnost“. Ponovno, taj zaključak dolazi iz „pravila“ da je mala vrijednost p upućuje na značajne razlike. Kako se izračun p -vrijednosti bazira na pretpostavci da je rezultat produkt same šanse (sreće), to se očigledno ne može koristiti za ocijenu vjerojatnosti da je pretpostavka istinita. To je suptilno različito od stvarnog značenja koji je, da je p -vrijednost šansa da nulta hipoteza objašnjava rezultat: rezultat ne može biti „samo slučajnost“ i biti objašnjen nultom hipotezom sa povjerenjem jednakim p -vrijednosti.
- P-vrijednost ne ukazuje na vjerojatnost da se odbija nulta hipoteza, zbog nedovoljno informacija dolazi do pogrešnog tumačenja
- P-vrijednost ne ukazuje na vjerojatnost, da ponavljanje eksperimenta neće voditi istim zaključcima
- P-vrijednost ne ukazuje na vjerojatnost da je alternativna hipoteza točna (prva točka)
- Razina značajnosti testa nije određena p -vrijednošću
Razina značajnosti testa je vrijednost koja bi trebala biti određena interpretacijom podataka prije nego što su prikazani, te se usporedba sa p -vrijednosti ili nekim drugim statističkim parametrom obavlja nakon što je izveden test.

3.5.2 ANDERSON-DARLING STATISTIKA

Mjeri koliko dobro podaci slijede određenu distribuciju. Što je bolja raspodjela podataka, to će biti manji iznos te statistike. Anderson-Darling statistika koristi se za usporedbu pogodnosti nekoliko distribucija, da bi se vidjelo koja je najbolja, i/ili za testiranje da li uzorak podataka dolazi iz populacije određene distribucije. Na primjer, možemo koristiti Anderson-Darling statistiku za biranje između Weibull i Lognormalne razdiobe za analizu pouzdanosti podataka ili za testiranje koji od podataka zadovoljava pretpostavku normalnosti za t -test.

Pretpostavke Anderson-Darling testa su:

- H_0 podaci slijede navedene distribucije
- H_1 : podaci ne slijede navedene distribucije

Ako je p vrijednost, (kada je dostupna) za Anderson-Darling test niža nego odabrane razine značajnosti (najčešće 0.05 ili 0.10), zaključuje se da podaci ne slijede navedene distribucije. Minitab ne pokazuje uvijek p vrijednost za anderson-darling test zato što on matematički ne postoji za određene slučajeve.

Pri nastojanju utvrđivanja koju distribuciju prate podaci i ako imamo veći broj Anderson-Darling statističkih podataka, provodi se njihova usporedba. Distribucija sa najmanjim AD podatkom najbolje odgovara podacima. U situaciji kada distribucije imaju isti AD izabire se ona koja se temelji na praktičnom znanju. Neke naredbe generiraju prilagođenu Anderson-Darling statistiku ili $A D^*$. Neprilagođeni parametri Anderson-Darling statistike koriste neparametarske skokovite funkcije bazirane na Kaplan-Meier ovoj metodi tj. proračunavanje točaka na grafu, dok prilagodljivi parametri Anderson-Darling statistike koriste i druge metode za proračunavanje točaka na grafu.

3.5.2.1 ANDERSON-DARLING TEST: GoF; GOODNESS OF FIT TEST

Postoje dva glavna pristupa za provjeru pretpostavke neke distribucije. Jedna uključuje empirijske postupke, koje je jednostavno razumjeti i primjeriti i bazira se na intuitivnim i grafičkim svojstvima distribucije koju želimo ocijeniti. Empirijski podaci koriste se za provjeru i testiranje pretpostavki distribucije. Tu su i druge statističke procedure za procjenu osnovnih podataka distribucije. To su Fit (GoF) testovi, tj. testovi specijalizirani za manje uzorke. Oni obično zahtijevaju specifičan softver za obavljanje opširnijih izračuna, no njihovi rezultati su mjerljivi i pouzdaniji od empirijskih postupaka. Među GoF postupcima posebno se ističu Anderson-Darling (AD) i Kolmogorov-Smirnov (KS) testovi. Oni se koriste pri procjeni Eksponencijalne, Weibullove, Normalne, Lognormalne distribucije. Navedene distribucije imaju široku primjenu u kvaliteti i pouzdanosti rada. U ovom dijelu nastojat će se prikazati kako se koristi GoF test (Anderson-Darling) pri interpretaciji normalne i Weibullove distribucije.


3.5.2.2 STATISTIČKA POZADINA

Za uspješnu implementaciju određenih statističkih postupaka prvo je potrebno utvrditi kako se podaci odnose tj. da li se podaci ponašaju normalno tj. da li se pokoravaju zakonu normalne razdiobe. To se može ispitati pomoću GoF testova. GoF testovi se baziraju na jedan od dva elemenata distribucije: kumulativnu funkciju distribucije (CDF) ili na funkciju gustoće vjerojatnosti (pdf). Hi-kvadrat test se bazira na pdf-u. AD i KS GoF testovi koriste pristup kumulativne funkcije distribucije i njihovo pripadanje testovima udaljenosti. Testovi AD i KS koje koristimo u procjenama odabrani su iz dva razloga: koriste se za testiranje malih uzoraka, a mogu se koristiti i za velike uzorke. Drugo, moguće je koristiti više različitih statističkih paketa za te testove i AD i KS testovi se često koriste u praksi. U ovom dijelu prikazat će se kako se koristi AD test u programskom paketu *Minitab*.

3.5.2.3 PREDNOSTI I NEDOSTACI AD I KS GoF-A I HI-KVADRAT TESTA

Kod velikih uzoraka bolje je koristiti Hi-kvadrat test. To ne zahtjeva poznavanje distribucijskih parametara koji su nužni pri uporabi AD i KS testova, te tako utječe na njihovu snagu. S druge strane, Hi-kvadrat test zahtjeva da broj podataka bude dovoljno velik za statistički test radi približavanja svojoj temeljnoj Hi-kvadrat distribuciji, nešto što AD i KS ne zahtijevaju.

Za provedbu testa udaljenosti, moramo slijediti definirani niz koraka. Prvo, definiramo, pretpostavimo distribuciju (npr. normalna distribucija), zatim se vrši procjena parametara distribucije (\bar{x} i varijance) iz podataka. Iz podataka se provodi test hipoteza (nulta hipoteza i alternativna). H_0 slijedi navedenu distribuciju, a H_1 ne slijedi. U testovima udaljenosti, kada je pretpostavljena distribucija *točna*, teoretski (pretpostavljeni) CDF (na slici obilježeno F_0) približno slijedi empirijsku funkciju CDF (obilježeno sa F_n). Podaci su dani u određenim uzorcima $\{x_1 < x_2 < \dots < x_n\}$ i pretpostavljena distribucija, koja slijedi nultu hipotezu, ima CDF, $F_0(x)$. Dobivamo i odgovarajuće statističke vrijednosti GoF testa. Konačno, uspoređuju se teoretski i empirijski rezultati. Ako se oni slažu, tada podaci slijede navedenu distribuciju. Ako ne, distribucijska pretpostavka se odbacuje.



Slika 17. Anderson- Darling test

Međutim, pri provođenju testa treba imati na umu važno upozorenje. Teoretski, testovi udaljenosti zahtijevaju poznavanje distribucijskih parametara, a oni su rijetko znani u praksi. To se može voditi kao nedostatak AD Gof-a koji je inače vrlo moćan postupak. Stoga, adaptivni postupci se koriste za zaobilazanje ovih problema prilikom provedbe GoF testova u praksi.

3.5.2.4 ANDERSON-DARLING GOF TEST

Anderson-Darling (AD) testiranje se često koristi za testiranje normalnosti i za testiranje Weibullove pretpostavke. Ukoliko postoji potreba za testiranje Lognormalne razdiobe potrebno je transformirati izvorne podatke i zatim koristiti AD test za normalnost na transformiranim podacima. U ovom dijelu će se nastojati prikazati kako se provodi test normalnosti i testiranje Weibullove pretpostavke.

AD Gof test za normalnost ima oblik:

$$A D = \sum_{i=1}^n \frac{1-2i}{n} \{ l n F_0[Z_{(i)}] + l n 1 - F_0[Z_{(n+1-i)}] \}^2 n; \dots$$

(3.18)


Gdje je F_0 je funkcija dobivena iz podataka za normalnu distribuciju (μ, σ); $Z(i)$ je sortirana, standardizirana vrijednost uzorka; „n“ je veličina uzorka; „ln“ je prirodni logaritam baze e i indeks „i“ se kreće od 1 do n.

Nulta hipoteza, (funkcija F_0 istinita) se odbija (na razini značajnosti = 0.05, za uzorak veličine n), ako je statistika AD testa veća od kritične vrijednosti (CV).

Odbiti ako:

$$AD > CV = \frac{0.752}{\left(1 + \frac{0.75}{n} + \frac{2.25}{n^2}\right)} \quad (3.19)$$

Osim toga, za dodatnu provjeru vjerodostojnosti podataka koristimo *Minitab softver* pomoću kojeg dobivamo AD plot.



Slika 18. Anderson –Darling test u programskom paketu Minitab

On nam je vrlo koristan i velika je prednost pri provođenju AD testa. On slijedi podatke dobivene formulom za AD test normalnosti. Izračunatom p vrijednosti također možemo ustvrditi normalnost.


Ako p vrijednost nije mala (oko 0.1 ili više) onda se može pretpostaviti da se podaci normalno ponašaju. Na kraju, ako točke (podaci) na grafu imaju trend linearnog rasta, to također pridonosi pretpostavci, da se povećava vjerojatnost da podaci slijede normalnu razdiobu.

Kod Lognormalne distribucije, prvo je potrebno izračunati logaritam podataka, znači transformirati podatke i nakon toga primijeniti AD GoF test. Ako su stvarni podaci lognormalni, tada je njihova transformacija normalno distribuirana, te se pri izračunu AD koristi ista formula kao i kod testiranja normalnosti.

Sažetak AD GoF testa za normalnost:

- Sortirati x uzorak i standardizirati ga uporabom $Z = \frac{(x - \mu)}{\sigma}$
- Postaviti nultu hipotezu H_0 : pretpostaviti normalnu distribuciju (μ, σ)
- Odrediti distribucijske parametre: μ, σ
- Odrediti podatke u tablici: $F(Z); l \leq F(Z) \leq u$ i s v š t o s e n a v o d i
- Odrediti AD i CV po navedenim formulama
- Ako je $AD < C$ i $CV < C$ podaci slijede normalnu distribuciju
- Ako je moguće, koristiti kompjutorske softvere- npr. *Minitab* i testirati p vrijednost

3.5.3 ANALIZA PODATAKA U PROGRAMSKOM PAKETU MINITAB (P-VALUE, AD)



Slika 19. Probability plot of warping

Na slici možemo vidjeti da se podaci ne ponašaju normalno. To se da zaključiti iz vrijednosti AD i P-value. Slijedeći korak je transformirati podatke.

Transformacija će se izvršiti pomoću Box-Cox metode.

3.5.4 TEORIJSKA RAZRADA BOX-COX TRANSFORMACIJE

3.5.4.1 PRETPOSTAVKA O NORMALNOSTI I BOX-COX TRANSFORMACIJA

Jedan od načina normalizacije podataka je Box-Cox transformacija. Box-Cox transformacija pretvara dobivene podatke u aproksimacijski set podataka. Formula za transformaciju glasi:

$$y = \frac{x^\lambda - 1}{\lambda} \quad (3.20)$$

gdje je y odzivni faktor (rezultat), a λ je transformacijski parametar.

Ako je $\lambda = 0$, nazivnik bi bio 0. Kako bi to izbjegli, koristimo prirodni logaritam:

$$y = \ln x \quad (3.21)$$

3.5.4.2 BOX-COX TRANSFORMACIJA

Box-cox transformacija ima široku primjenu pri transformaciji zavisne varijable. Također ima svojstvo smanjenja ili uklanjanja korelacije između srednje vrijednosti grupe podataka i njezine standardne devijacije. Često je važno transformirati varijable skupa podataka prije izvođenja bilo kakve analize ili modeliranja, jer taj postupak uvelike povećava kvalitetu podataka. Ovaj postupak, odnosno, preobrazba originalnih podataka na način koji će pomoći naknadnoj analizi i modeliranju, općenito je poznat kao predobrada podataka.

Takve transformacije su se pokazale vrlo korisne u statističkom modeliranju, kao i u regresijskoj analizi. Općenito mnoge statističke analize tek će raditi pod uvjetom normalnosti. Stoga transformacijom izvorne varijable u normalnu distribuiranu varijablu omogućavamo primjenu mnogih statističkih tehnika koje zahtijevaju normalizirane podatke.

Posebna skupina transformacija koje imaju za cilj transformaciju originalnih podataka na način da nove varijable imaju distribuciju što bližu normalnoj je Box-Cox metoda.

Box-Cox metoda započinje transformacijskim parametrom λ , a definirana je formulom:

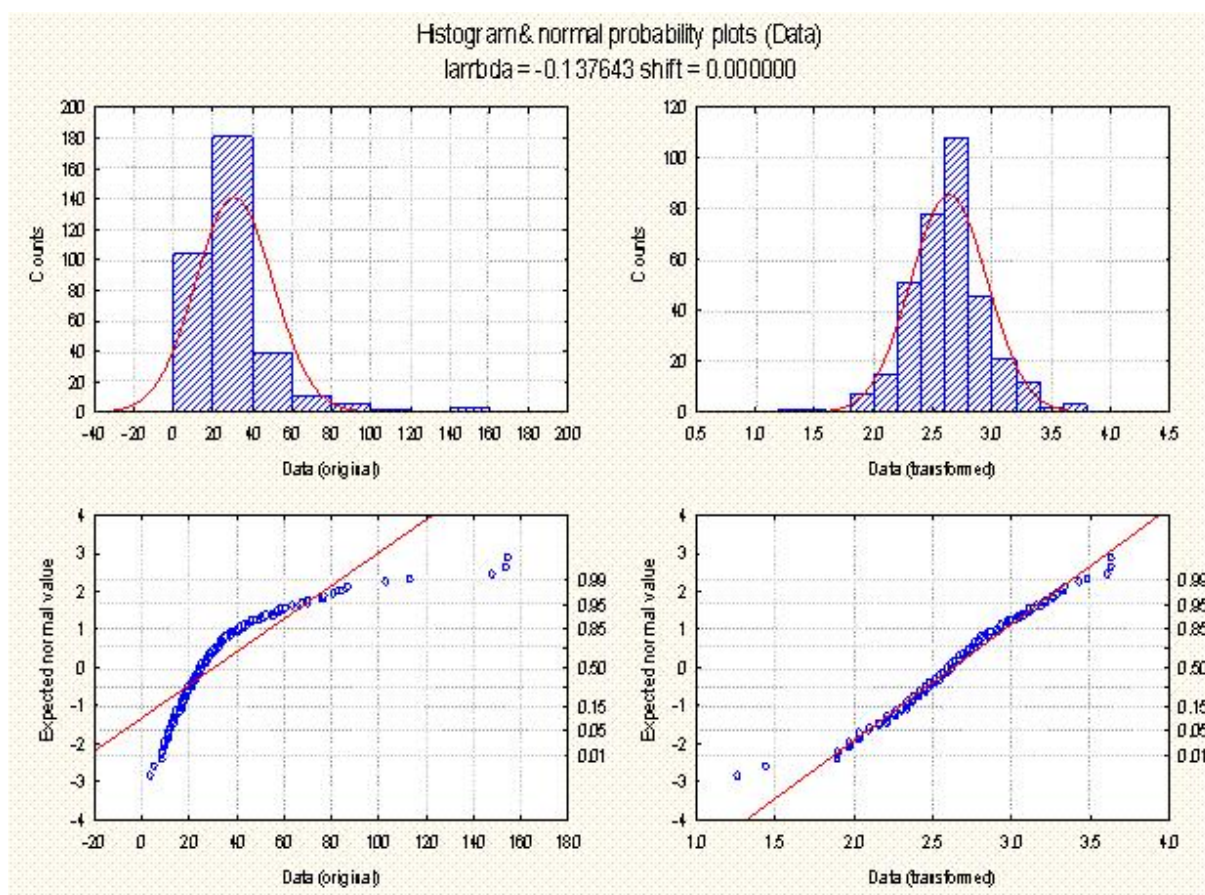
$$\tilde{x} = \left\{ \frac{(x + \alpha)^\lambda - 1}{\lambda} \right\}, \text{ za } \lambda \neq 0$$

$$\tilde{x} = \left\{ \frac{(x + \alpha)}{1 + \alpha x} \right\}, \text{ za } \lambda = 0$$

(3.22)

gdje \tilde{x} je varijabla koju transformiramo, a α je poznati parametar pomaka.

Cilj Box-Cox transformacije je pretvorba varijable x tako da se rezultira novom varijablom \tilde{x} koja će biti dovoljno blizu normalnoj distribuciji.



Slika 20. Transformacija podataka uporabom Box- Cox metode

Gornja slika prikazuje posljedicu Box-Cox transformacije na varijablu koja odstupa od normalne distribucije (lijeva strana slike). Nakon provedene transformacije nova varijabla (transformirana) ima distribuciju koja je približno slična normalnoj (desna strana slike).

Za primjenu Box-Cox transformacije potrebno je pronaći odgovarajuću vrijednost λ označenu sa $\tilde{\lambda}$ koja vodi transformiranu varijablu bliže normalnosti.

Postoji nekoliko tehnika pristupa ovom problemu, kao što su pronalaženje optimalne vrijednosti λ koja najbolje zadovoljava pretpostavku normalnosti.

Jedan od pristupa poznat je pod nazivom maksimalna vjerojatnost u kojem se konstruira kriterij pogreške E definiran kao minus logaritam vjerojatnosti funkcija:


$$E(\lambda) = -\frac{N}{2} \log(\sigma^2) + (\lambda - 1) \sum_{i=1}^N \log(\tilde{x}_i) \quad (3.23)$$

gdje je $\sigma^2(\lambda)$ je standardna devijacija transformirane varijable \tilde{x} . Vrijednost λ , koja minimizira gore navedenu jednadžbu je optimalna $\tilde{\lambda}$ za Box-Cox transformaciju.


Pronalaženje λ zahtjeva iterativnu proceduru. Iterativna procedura započinje sa minimalnom vrijednošću λ , zatim se provodi Box-Cox transformacija, te se potom izračunava funkcija pogreške.

Ovaj proces se ponavlja za različite vrijednosti λ sve dok se ne nađe prikladan vrijednost λ za koju je funkcija pogreške minimalna.

Distribucija podataka Transformacija Transforirana distribucija



Distribucija podataka Transformacija Transformirana distribucija




Slika 21. Box-Cox transformacija distribucija

λ (Power)	Y^λ	Common Names
-2	$\frac{1}{Y^2}$	Reciprocal (inverse) squared
-1	$\frac{1}{Y}$	Reciprocal (inverse)
-0.5	$\frac{1}{\sqrt{Y}}$	Reciprocal square root (inverse)
0 ⁽¹⁾	Log(Y)	Log
0.5	\sqrt{Y}	Square root
1	No transformation	---
2	Y^2	Squared

Slika 22. Ovisnost promjene λ ovisno o prirodi distribuciji


Iz slike se vidi postupak transformacije podataka.

3.5.5 ANALIZA PODATAKA U PROGRAMSKOM PAKETU MINITAB (LAMBDA, PROBABILITY PLOT NAKON BOX-COX TRANSFORMACIJE)




Slika 23. Box-Cox plot of warping - lambda

Minitab jednostavno pronalazi optimalnu vrijednost lambde koja može biti bilo koja vrijednost između -5 i 5. Iz slike 23 se vidi da je za zadane podatke sugerirana vrijednost 0.5. To je vrijednost koja najbolje normalizira podatke.



Slika 24. Probability plot - podaci nakon Box-Cox transformacije

Iz slike 24 se može vidjeti da su podaci normalizirani. To se vidi po iznosima AD i p-value.



Slika 25. Probability plot of warping; C2

Slika 25. Prikazuje raspodjelu podataka prije i nakon Box-Cox transformacije.

3.6 DRUGA FAZA

3.6.1 TEORIJSKA RAZRADA SPOSOBNOSTI PROCESA

3.6.1.1 SPOSOBNOST PROCESA SA NORMALNO DISTRIBUIRANIM PODACIMA

Podatke vezane uz sposobnost procesa (indekse) možemo podijeliti u dvije skupine:

- Indekse potencijalne sposobnosti
- One koje mjere njihove stvarne sposobnosti

Potencijalni indeksi sposobnosti određuju koliko proces može biti sposoban, ako su ispunjeni određeni uvjeti. Ako \bar{x} normalnog distribuiranog procesa je orijentirana na cilj koji je projektiran.

Stvarni indeksi sposobnosti procesa određuju kako se proces zapravo ponaša u stvarnosti. Indeksi su pojedinačni, oni nisu izraženi u odnosu na već određene jedinice procesa. Za karakterizaciju sposobnosti procesa treba uzeti u obzir i varijacije proizvodnog procesa koje se pojavljuju u tijeku procesa. Te varijacije su izmjerene u odnosu na kako se proces mijenja iz svog izvornog položaja zbog kombinacije od zajedničkih uzroka varijacija i prilagodbe koja je načinjena od korigiranih specijalnih uzoraka. Mijenjanje procesa ima utjecaj na širenje kontrolne karte i stoga utječe na mogućnost procesa da zadovolji potrebe kupaca u duljem vremenskom razdoblju.

Sposobnost procesa u kratkom vremenskom razdoblju (short term) procjenjuje se pokazateljima kao što su: C_p , C_{pk} i C_r . Kada se procjenjuju svojstva u duljem vremenskom razdoblju (long term) procjenjuje se pokazateljima kao što su: P_p , P_{pk} i P_r .

Formule za izračunavanje sposobnosti i izvedbu su vrlo slične. Razlika je tome da je vrijednost sigma različita i ovisi da li rješavamo dugoročne ili kratkoročne varijacije.

3.6.1.2 PROCJENA SIGME

Budući da je proces širenja uvijek jednak šest sigma, varijabla koja objašnjava raspon između gornje granice kontrole (UCL) i donje granice kontrole (LCL) je sigma, standardna devijacija. Vrijednost sigme ovisi o kratkoročnim i dugoročnim varijacijama. Sigma za kratkoročne varijacije (short-term) se računa samo za prirodne varijabilnosti procesa, dok se za dugoročne varijabilnosti uzima u obzir i mijenjanje procesa zbog kombinacije varijacija zbog zajedničkih i prenosivih (dodijeljenih) uzoraka.

3.6.1.3 Z VRIJEDNOSTI

Z vrijednosti označuju položaj pojedinog rezultata u nekoj razdiobi. Z vrijednosti su jedan od najpoznatijih načina baždarenja nekog testa. Standardizirano obilježje z je linearna transformacija vrijednosti numeričke varijable X . Transformacija se provodi tako da se odstupanja vrijednosti numeričke varijable od njezine aritmetičke sredine izrazi u dijelovima standardne devijacije. Standardizirana varijabla omogućuje usporedbu položaja podataka u jednom nizu i u kvalitativno različitim numeričkim nizovima. Jednadžba za z transformaciju glasi:

$$z = \frac{X - \mu}{\sigma} \quad (3.24)$$

Z distribucija ovisi o parametrima σ i μ . Z vrijednost pokazuje koliko je numerička varijabla X pomaknuta u lijevo (kada je Z negativan), odnosno u desno (kada je z pozitivan) od aritmetičke sredine. Vrijednost z se koristi za pronalazak vjerojatnosti povezane sa tablicom z distribucije.

Z vrijednosti se kreću od -3 do +3 (s aritmetičkom sredinom 0), a katkada se zbog praktičnosti z vrijednostima dodaje broj 5, pa se dobiva skala od 2 do 8. U tom slučaju z vrijednosti se nazivaju standardnim vrijednostima.

3.6.1.4 VEZA Z TRANSFORMACIJE I SPOSOBNOSTI PROCESA

Za normalno distribuirane podatke lako je naći vezu između C_{pk} i Z distribucije te je iz Z transformacije moguće procijeniti broj defekata (PPM).

Ako je :

$$C_{U L} = \frac{1}{3} Z_{U L} = \frac{U S L - \bar{x}}{3\sigma_{ST}} \quad (3.25)$$

i

$$C_{L L} = \frac{1}{3} Z_{L L} = \frac{\bar{x} - L S L}{3\sigma_{ST}} \quad (3.26)$$

Odnosno

$$C_{pk} = \frac{Z_{min}}{3} \quad (3.27)$$

Ili

$$Z_{min} = 3C_{pk} \quad (3.28)$$

Gore navedene formule omogućavaju nam izračun vjerojatnosti događaja te kumulativnu vjerojatnost da će se podaci normalno distribuirati u nekom događaju.

3.6.1.5 POTENCIJALNA SPOSOBNOST

Potencijalna sposobnost pokazuje da li će proces biti sposoban da zadovolji očekivanja kupca u određenim uvjetima koje proces mora ispuniti. Potencijalni pokazatelji koji se češće koriste su C_p i C_r . Izlazni podaci za većinu proizvodnih procesa se normalno distribuiraju, tako da pri prikazu grafa normalne distribucije, 99.73% podataka (opažanja) će biti koncentrirana između $\pm 3\sigma$ gledajući od \bar{x} , u rasponu od 6σ .

3.6.1.5.1.1 KRATKOROČNA POTENCIJALNA SPOSOBNOST PROCESA (SHORT-TERM); C_p I C_r

Sposobnost procesa se određuje usporedbom širenja podataka unutar kontrolne karte sa dodijeljenom proizvodnom specifikacijom. Proces je potencijalno sposoban ako je širenje prirodnih varijacija manji od specificiranih (određenih) granica. To je tako kada je omjer procesa, koji ima svoje specificirane granice (UCL i LCL) koje određujemo pomoću σ , sa specificiranim rasponom (USL, LSL) veći od 1. Drugim riječima, dobiveni omjer bi trebao biti veći od 1.

$$C_p = \frac{USL - LSL}{UCL - LCL} \quad (3.29)$$

Raspon na kontrolnoj karti se dobije oduzimanjem LCL iz UCL i pošto je

$$UCL = \mu + 3\sigma_{\bar{X}} \text{ i } LCL = \mu - 3\sigma_{\bar{X}} \\ RASPC = UCL - LCL = (\mu + 3\sigma_{\bar{X}}) - (\mu - 3\sigma_{\bar{X}}) = \mu + 3\sigma_{\bar{X}} - \mu + 3\sigma_{\bar{X}} = 6\sigma_{\bar{X}} \quad (3.30)$$

Dakle, raspon kontrolne karte je uvijek jednak $6\sigma_{\bar{X}}$. Uvrštavanjem u formulu za C_p dobivamo:

$$C_p = \frac{USL - LSL}{UCL - LCL} = \frac{USL - LSL}{6\sigma_{\bar{X}}} \quad (3.31)$$

$C_p = 1$, ako je specificirani raspon jednak rasponu prirodnih varijacija procesa. U tom slučaju proces je jedva sposoban. Ima potencijal da proizvodi samo nedefektne proizvode ako je postupak odnosno proces usredotočen, centriran na cilj ($\bar{x} = target$). Približno 0.27% ili 2700 PPM (dijelova na milion) su defektni.

$C_p > 1$, ako je specificirani raspon veći od raspona procesa. Proces je potencijalno sposoban ako je usredotočen na proizvodno određen cilj, odnosno ($\bar{x} = target$) i vjerojatno proizvodi proizvode koji zadovoljavaju ili čak premašuju zahtjev kupca.

$C_p < 1$, ako je specificirani raspon manji od raspona procesa. Proces je nesposoban i može se reći da tvrtka proizvodi puno škarta i da se takav način proizvodnje po *Lean filozofiji* ne isplati.

Drugi način izražavanja kratkoročne potencijalne sposobnosti procesa je koristeći omjer sposobnosti C_r . To ukazuje na omjer ili postotak širenja specificiranog raspona koji je potreban da se uopće održi raspon procesa, da bi proces uopće bio sposoban.

$$C_r = \frac{1}{C_p} = \frac{USL - LSL}{USL - LSL} \frac{6\sigma_{ST}}{USL - LSL} \quad (3.32)$$

3.6.1.5.2 DUGOROČNI POTENCIJALNI UČINAK

Dugoročni (long-term) potencijalni učinak se računa sličnim metodama kao i C_p i C_{pk} s tom razlikom da se standardna devijacija računa po formuli za dugoročne varijacije.

$$P_p = \frac{USL - LSL}{6\sigma_{LT}} \quad (3.33)$$


A omjer učinka se računa

$$P_r = \frac{6\sigma_{LT}}{USL - LSL} \quad (3.34)$$

3.6.1.6 STVARNE SPOSOBNOSTI

Potencijalna sposobnost procesa uzima u obzir samo raspon specificiranih granica i širenje procesa. Time se pokazuje samo potencijal, zato što širenje procesa zbog prirodne varijabilnosti može biti manje od specificiranih granica, a proces još uvijek proizvodi defekte. Donja slika prikazuje kontrolnu kartu na kojoj možemo vidjeti širenje procesa koje je manje od specificiranih granica, ali zato što proces nije centriran on proizvodi defekte.

Ako \bar{x} samog procesa nije centriran na zadan cilj, C_p će samo ukazati koja od dva raspona (kontrolne granice samog procesa ili projektirano specificirane granice) je širi, ali nas neće moći obavijestiti o tome da li proces proizvodi defekte.



Slika 26. Prikaz sposobnosti procesa

U tom slučaju koristimo drugi indeks sposobnosti za određivanje sposobnosti postupka da udovolji zahtjevima kupaca. C_{pk} mjeri koliko proizvodnog procesa zaista odgovara projektiranim specifikacijama. K u C_{pk} se naziva *k-faktor*.

On mjeri razinu varijacija $\bar{x} - z$ au odnosu na specificirani cilj (*target*).

$$C_p \neq (1 - k)C_p$$

(3.35)

gdje je:

$$k = \frac{\left[\frac{(U \text{ } S \text{ } \vdash \text{ } L \text{ } S) \text{ } \mathcal{D}}{2 - x^{\overline{}}} \right]}{\frac{(U \text{ } S \text{ } \vdash \text{ } L \text{ } S) \text{ } \mathcal{L}}{2}} \quad (3.36)$$

Kada je $k=0$, znači da je proces savršeno centriran i stoga je $C_{pk}=C_p$. Ako je $k \neq 0$, tada je $C_p \neq m$ i $\{C_U, C_L\}$, C_p će biti manji od oba, gdje:

$$C_{U \text{ } L} = \frac{1}{3} Z_{U \text{ } L}$$

$$C_{L \text{ } L} = \frac{1}{3} Z_{L \text{ } L}$$

i

$$Z_{U \text{ } L} = \frac{U \text{ } S \text{ } \vdash \text{ } x^{\overline{}}}{\sigma_{S \text{ } T}}$$

$$Z_{L \text{ } L} = \frac{x^{\overline{}} - L \text{ } S \text{ } L}{\sigma_{S \text{ } T}}$$

(3.37)

Indeksi sposobnosti za dugoročan proces (long term) dobiveni su na sličan način.

$$P_p \neq m \text{ i } n \left\{ \frac{1}{3} Z_{U \text{ } 1/L \text{ } T} \text{ } \frac{1}{3} Z_{L \text{ } 1/L \text{ } T} \right\}$$

(3.38)

gdje,

$$Z_{U\ 1/L\ T} = \frac{U\ S\ L\ \bar{x}}{\sigma_{L\ T}} \quad (3.39)$$

i

$$Z_{L\ 1/L\ T} = \frac{\bar{x} - L\ S\ L}{\sigma_{L\ T}} \quad (3.40)$$

3.6.1.7 INDEKSI SPOSOBNOSTI I DIJELOVI NA MILIJUN-PPM

Indeksi sposobnosti procesa dolaze bez jedinice. Drugim riječima, nisu izraženi u metrima, gramima.. Iz tog razloga nije uvijek jednostavno objasniti njihovo značenje, tj. potrebno je donekle poznavati statistiku za njihovo razumijevanje. Na primjer, ako je na početku nekog procesa iznos C_{pk} procesa jednak 0.78. Nakon što je uslijedilo poboljšanje, ono iznosi 1.26. Iz toga se može zaključiti da je došlo do poboljšanja proizvodnog procesa. Međutim, na osnovu dva podatka ne može jednostavno svatko razumjeti da oni prikazuju da je došlo do smanjenja defekata u procesu.

Upravo podatak o dijelovima na milijun (PPM) koji izlaze izvan specificiranih granica mogu pomoći u tom nedostatku podataka. PPM mjeri koliko dijelova od milijun proizvedenih su neispravni. Procjena broja neispravnih dijelova od milijun proizvedenih olakšava svakome, čak i laiku, vizualiziranje i shvaćanje na kojoj razini kvalitete se nalazi proizvodni proces.

3.6.1.8 SPOSOBNOST PROCESA I Z TRANSFORMACIJA

Z transformacijom može se procijeniti broj neispravnih dijelova (PPM). Z formula od normalne distribucije glasi:

$$Z = \frac{x - \mu}{\sigma} \quad (3.41)$$

Upratebljavajući formule vezane uz Z transformaciju, tj. formule koje vežu Z transformaciju uz sposobnost procesa možemo preko istih formula doći do izračuna PPM-a. Ukupni PPM se dobiva dodavanjem vrijednosti dobivenog PPM-a sa svake strane specificirane granice.

$$PPM_U = 10^6 \Omega(Z_U) = 10^6 \Omega\left(\frac{U - \mu}{\sigma}\right) \quad (3.42)$$

$$PPM_L = 10^6 \Omega(Z_L) = 10^6 \Omega\left(\frac{\mu - L}{\sigma}\right) \quad (3.43)$$

$\Omega(Z_U)$ i $\Omega(Z_L)$ predstavljaju vrijednosti Z_U i Z_L koje su dobivene iz normalne razdiobe.

$$PPM = PPM_U + PPM_L \quad (3.44)$$

Postoji stalna povezanost između vrijednosti C_{pk} , Z_{min} i PPM-a kada je proces centriran.

Tablice, koje prikazuju rezultate nekog procesa sadrže potencijalne sposobnosti koje se označuju sa (within), te očekivane preformanse procesa (overall)- vezano uz PPM.

Potencijalne sposobnosti sadrže podatke:

- Potential (within) capability- potencijalne sposobnosti

$$C_p = \frac{USL - LSL}{6\sigma}$$


Očekivane preformanse sadrže podatke:

- Expected (overall) performance- očekivane preformanse:

$$C_{pk} = \frac{\min(\bar{x} - LSL, USL - \bar{x})}{3\sigma}$$

$$C_{pk} = \frac{\min(\bar{x} - LSL, USL - \bar{x})}{3\sigma}$$


$$C_{pk} = \frac{\min(\bar{x} - LSL, USL - \bar{x})}{3\sigma}$$



Slika 27. Tumačenje sposobnosti procesa

Na slici 27 može se vidjeti kako se ti podaci mogu tumačiti preko grafikona.

3.6.2 ANALIZA PODATAKA SPOSOBNOSTI PROCESA



Slika 28. Process capability of warping

Analiza sposobnosti procesa (slika 28.) temelji se na Z- transformaciji, koja se koristi kada su podaci normalizirani. Kao što samo već ranije napomenuli, podaci nisu normalno distribuirani. Koristeći Box-Cox transformaciju podaci su normalizirani, ali prema indexima sposobnosti može se zaključiti da proces nije sposoban, te će se pomoću Taguchi-jevih principa nastojati poboljšati.

3.6.3 TEORETSKA RAZRADA TAGUCHI-JEVIIH PRINCIPA

Indeksi koji su korišteni u dosadašnjim razmatranjima (C_p , C_{pk} , P_p , P_{pk} i C_r) uzimaju u obzir specificirana ograničenja (USL, LSL), standardnu devijaciju, a u slučaju C_{pk} i P_{pk} proizvodni proces. Nijedan od ovih indeksa ne uzima u obzir varijacije unutar tolerancija, varijacije koje se javljaju zato što \bar{x} ne slijedi određenu (ciljanu) vrijednost, ali su još uvijek u specificiranim granicama. Taguchi-ev pristup kontroli procesa sugerira da svaka varijacija od projektiranog, određenog cilja (*target*), bila ona izvan ili unutar specificiranih granica je izvor defekta i trošak za proizvodnju. Gubitak je proporcionalan udaljenosti između aritmetičke sredine procesa i ciljne vrijednosti (*target*). Zbog takvog pristupa vrijednostima koje se nalaze oko ciljne vrijednosti, definicija i pristup mjerama sposobnosti uvelike se razlikuje od klasičnog pristupa analize sposobnosti procesa. Primjerice, imamo procese koji su zadovoljavajući sa vrijednostima C_{pk} , C_p , P_{pk} , P_k većim od 1, ali vrijednosti procesa ne pogađaju ciljanu vrijednost što navodi da je C_{pm} je manji od 1. Prema Taguchi-u, taj proces se smatra nesposobnim.

Prema Taguchi-u indeks koji se koristi za mjerenje sposobnosti procesa se označava sa C_{pm} i on se računa:


$$C_{pn} = \frac{US - LSL}{6\sqrt{\sigma_S^2 + (\mu - T)^2}} \quad (3.45)$$

Gornja jednačba pokazuje da je C_{pm} funkcija obje vrijednosti, σ_S i razlike između aritmetičke sredine procesa i ciljne vrijednosti T. Ako je vrijednost razlike ($\mu - T$)=0, tada

$$C_{pn} = \frac{US - LSL}{6\sqrt{\sigma_S^2 + (\mu - T)^2}} = \frac{US - LSL}{6\sqrt{\sigma_S^2 + 0}} = \frac{US - LSL}{6\sigma_S} = C_p \quad (3.46)$$

što daje zaključiti, ako je aritmetička sredina μ jednaka ciljanoj vrijednosti T, C_p će biti jednak C_{pm} .

3.6.4 ANALIZA PODATAKA UPORABOM TAGUCHI-EVIH PRINCIPA



Slika 29. Process capability of warping

Pomoću grafa (slika 29.) se može vidjeti da primjenom Taguchi-evih principa nije došlo do naročitih poboljšanja procesa, te se i dalje može reći da proces nije sposoban.

3.7 TREĆA FAZA

3.7.1 TEORETSKA RAZRADA WEIBULLOVE RAZDIOBE

U teoriji vjerojatnosti i statistici, Weibullova distribucija je kontinuirana distribucija vjerojatnosti. Ime je dobila po Waloddi Weibull koji ju je detaljno opisao 1951, iako ju prvi primjenjuju Rosin i Rammler (1933) za opis raspodjele veličine čestica. Funkcija gustoće vjerojatnosti slučajne varijable x :

$$f(x; \lambda, k) = \begin{cases} \frac{k}{\lambda} \left(\frac{x}{\lambda}\right)^{k-1} e^{-(x/\lambda)^k}, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.47)$$

gdje je $k > 0$,parametar oblika i $\lambda > 0$ je parametar veličine distribucije, a komplementirana kumulativna funkcija distribucije je ispružena eksponencijalna funkcija. Weibullova distribucija je povezana sa mnogim drugim distribucijama vjerojatnosti, a naročito je interpolirana između eksponencijalne distribucije ($k = 1$) i Rayleighove distribucije ($k = 2$).

Weibull – ova distribucija doista je univerzalni model sa širokom lepezom aplikacija i to zahvaljujući matematičkim karakteristikama, kojima se prilagođava svim distribucijskim funkcijama.


Tablica 4. Parametri oblika k za distribucijske modele

Parametar oblika k	Distribucijski model
$k = 1$	Eksponencijalna distribucija
$1,5 \leq k \leq 3$	Lognormalna distribucija
$k = 2$	Rayleigh – ova distribucija
$3,1 \leq k \leq 3,6$	Lognormalna distribucija
$k = 3,6$	Normalna distribucija

Glavna uporaba je za procjenu pouzdanosti i za probleme u procjeni vijeka trajanja. Po parametru oblika k se razlikuje Weibullova razdioba i njeno tumačenje (na primjer kod kvarova):

- Vrijednost $k < 1$ značava da se učestalost kvara smanjuje s vremenom. To se događa ako postoji značajan broj neispravnih stavki na početku i one se s vremenom počinju smanjivati, jer se neispravni dijelovi izbacuju iz uporabe.
- Vrijednost $k = 1$ znači da je učestalost kvarova konstantna tijekom vremena. To bi moglo sugerirati da neki slučajni vanjski događaj uzrokuje taj problem.
- Vrijednost $k > 1$ znači da kvarovi učestalo rastu s vremenom. To se događa ako imamo proces „starenja“, samog procesa ili dijelova koji će se vjerojatno s vremenom kvariti.

3.7.2 ANALIZA PROCESA UPORABOM WEIBULLOVE RAZDIOBE



Slika 30. Process capability of warping

Iznos $P_{p\ k}$ (slika 30.) je mnogo manji od zadanog praga kvalitete, koji iznosi 1.33, te se može zaključiti da proces nije sposoban. Treba imati na umu da vrijednosti P_p i $P_{p\ k}$ nisu bazirane na μ i σ , već na parametrima distribucija koje promatrani podaci slijede (u ovom slučaju podaci slijede Weibullovu distribuciju).

3.7.3 TEORETSKA RAZRADA LOGNORMALNE RAZDIOBE

Lognormalna distribucija u teoriji vjerojatnosti je distribucija vjerojatnosti slučajne varijable čiji je logaritam normalno distribuiran.

Ukoliko promotrimo problem log normalne distribucije i pretpostavimo da je y normalno distribuirana slučajna varijabla, tada $x = \exp(y)$ ima log normalnu distribuciju. Isto tako, ako je x log normalno distribuirana varijabla, tada je $y = \log(x)$ normalno distribuiran. Ovo pravilo vrijedi bez obzira na baze logaritamskih funkcija.

Varijabla može biti modelirana kao log normalna, ukoliko je multiplikativni produkt više nezavisnih varijabli.

Primjeri iz stvarnog života su slučajevi računanja dugoročnih diskontnih faktora koji se izводе iz kratkoročnih faktora, duljina trajanja proizvodnje, računanje plaća zaposlenika itd..


Obilježja Lognormalne distribucije:

- distribucija vjerojatnosti slučajne varijable čiji logaritmi (baze 10 ili e) slijede normalnu distribuciju;
- izrazito je zakrivljena u desno;
- kada logaritmiramo vrijednosti varijable čija distribucija je zakrivljena prema desno, dobiveni logaritmi slijede normalnu distribuciju;
- kao mjera centralne tendencije upotrebljava se geometrijska sredina.

Ako y ima normalnu distribuciju sa očekivanjem α i varijancom β^2 tada možemo napisati što je lognormalna varijabla sa funkcijom gustoće vjerojatnosti:


$$f(x) = \frac{1}{\beta x} \frac{1}{\sigma \sqrt{2\pi}} \exp\left\{-\frac{(\ln x - \alpha)^2}{2\sigma^2}\right\}$$

(3.48)



Slika 31. Utjecaj parametara na oblik Lognormalne raspodjele

3.7.4 ANALIZA PROCESA UPORABOM LOGNORMALNE RAZDIOBE



Slika 32. Process capability of warping

Iz podataka (P_p i $P_p k$) se može vidjeti da proces (slika 32.) nije sposoban i da je potrebna detaljna analiza proizvodnog procesa.

4. ANALIZA PODATAKA I PROCJENA SPOSOBNOSTI PROCESA PROTUPOŽARNOG PREMAZA

PREDMET ISPITIVANJA: ispitivanje ukupne debljine sloja protupožarnog premaza na čeličnoj konstrukciji objektu Euroherc u Zagrebu (Slika 33).



Slika 33. Čelična konstrukcija

OPREMA: uređaj za mjerenje debljine suhog filma (ELCOMETER 456)

PRIMJENJENI PROPISI: certifikat za korišteni premaz, izdan od strane proizvođača

(HEMPEL d.o.o), za klasu F90

Vrste profila koji su ispitani:

- CHS-355.6×12.5, gdje je D.S.F = 2.65-za GLAVNE NOSAČE
- CHS 168,3×8,gdje je D.S.F=2.85- za SPOREDNE NOSAČE

Po rezultatima D.G.T možemo vidjeti da su kriteriji za glavne nosače, što se tiče debljine premaza blaži. To je samo zato što je njihov faktor presjeka manji, a to znači da im je deblja stjenka profila. Time je konstrukcija stabilnija i jača, ako slučajno dođe do požara. Prema certifikatu je zato potrebna i manja debljina premaza.

PLAN ISPITIVANJA: mjerenje ukupne debljine suhog filma boje provedeno je na
odabranim sekcijama čelične konstrukcije

- Glavni nosač 1
- Sporedni nosači 1

Ispitivanje koje je izvršeno na svakoj skupini nosača obuhvaća 75 mjerenja. Rezultati ispitivanja ukupne debljine protupožarnog premaza prikazani su softverskom paketu Minitab.

Analiza podataka dana je u točki 3, gdje je ujedno dana i procjena sposobnosti procesa za navedene podatke.

Glavni nosač 1




Slika 34. Glavni nosač

TABLICA 5. Debljine premaza u (mm) na glavnom nosaču 1.

3,84	5,10	3,80	4,60	4,31
3,58	4,23	3,85	4,11	4,05
4,49	3,68	4,06	3,75	4,00
4,41	3,85	3,80	4,50	3,77
4,33	4,21	3,40	4,05	3,58
4,60	3,90	4,65	3,80	4,01
4,95	3,95	5,10	3,70	3,72
4,51	4,05	4,80	4,12	3,60
4,45	4,00	5,35	3,48	3,80
4,20	4,15	4,67	4,61	3,70
4,15	4,70	3,59	3,80	3,64
4,21	4,87	3,70	4,26	3,60
4,49	4,60	3,62	4,14	3,40
4,25	3,70	5,14	3,80	3,95
5,06	3,90	5,20	3,90	4,08

Sporedni nosač 1.




Slika 35. Sporedni nosači

Tablica 6. Debljine premaza u (mm) na sporednom nosaču 1

2,61	2,59	3,63	2,86	3,85
2,97	3,45	2,67	3,11	3,47
2,85	4,27	3,25	3,26	3,48
2,61	2,56	3,12	2,85	2,84
2,39	2,77	2,83	2,93	2,91
2,85	2,52	2,85	3,25	3,28
3,56	2,73	3,01	3,36	2,95
4,52	2,51	2,71	2,90	3,05
3,17	2,32	2,65	3,70	2,89
3,45	3,38	2,67	3,68	2,77
2,92	2,74	2,86	3,21	3,21
2,53	3,25	2,87	3,83	3,36
3,00	3,60	2,97	3,36	3,71
3,78	2,51	3,00	3,05	3,54
3,35	3,33	2,80	3,40	4,01

4.1 ANALIZA PROTUPOŽARNOG PREMAZA $\bar{X} - R$ KARTOM


Analiza je izvršena pomoću softverskog paketa Minitab. Analiziraju se podaci glavnog nosača, te sporednih nosača. Dobiveni rezultati su dani u nastavku.



Slika 36. $\bar{X} - R$ karta glavnog nosača 1; veličina uzorka: 5

Slika 36. prikazuje raspodjelu podataka glavnog nosača. Dobivenom kontrolnom kartom se može vidjeti da postoje odstupanja u podacima, tj. da postoji uzorak koji izlazi izvan kontrolnih granica. Uzorak koji izlazi izvan kontrolnih granica potrebno je eliminirati. Eliminirali smo uzorak broj 8 ili podatke: 36, 37, 38, 39, 40.


Eliminacijom dobivamo novu raspodjelu podataka unutar kontrolne karte. Ona je dana grafom:



Slika 37. $\bar{X} - R$ karta glavnog nosača 1, nakon eliminacije uzorka 8.

Iz grafa se može vidjeti da niti jedan uzorak ne izlazi izvan kontrolnih granica samog procesa, te nije potrebna daljnja korekcija podataka. Proces je u stanju statističke kontrole.

Dan je i prikaz podataka za sporedne nosače.




Slika 38. $\bar{X} - R$ karta sporednih nosača 1.

Iz grafa se može ustvrditi da je proces u stanju statističke kontrole.

Analizom i korekcijom podataka glavnih i sporednih nosača proces je u stanju kontrole i moguće ga je koristiti pri procjeni sposobnosti procesa.


4.2 P-VRIJEDNOST, AD ANALIZA



Slika 39. Probability plot glavnog nosača 1.

Na slici 39 možemo vidjeti da se podaci ne ponašaju normalno. To se da zaključiti iz vrijednosti AD i P-value.


Vrijednost p je manja od 0.005, a AD vrijednost je obrnuto proporcionalna p vrijednosti. Slijedeći korak je transformirati podatke. Transformacija će se izvršiti pomoću Box-Cox metode.




Slika 40. Probability plot sporednih nosača 1

Iz slike se također može vidjeti da podaci za sporedni nosač ne prate u potpunosti normalnu razdiobu. Također je potrebna transformacija.

4.3 PROCJENA VRIJEDNOSTI LAMBDA




Slika 41. Određivanje lambde za glavni nosač 1




Slika 42. Određivanje lambde za sekundarne nosače

Minitab jednostavno pronalazi optimalnu vrijednost lambde koja može biti bilo koja vrijednost između -5 i 5. Iz slika se vidi da je za dane podatke sugerirana vrijednost -1. To je vrijednost koja najbolje normalizira podatke danih nosača.

4.4 PODACI NAKON BOX-COX TRANSFORMACIJE




Slika 43. Podaci glavnog nosača nakon Box-Cox transformacije



Slika 44. Podaci sporednih nosača nakon Box-Cox transformacije

Iz slika se može vidjeti da su podaci normalizirani. To se vidi po iznosima AD i p-value.


4.5 ANALIZA PODATAKA SPOSODNOSTI PROCESA



Slika 45. Sposobnost procesa glavnog nosača

Analiza sposobnosti procesa (slika 45.) temelji se na Z- transformaciji, koja se koristi kada su podaci normalizirani.


Kao što samo već ranije napomenuli, podaci nisu normalno distribuirani. Koristeći Box-Cox transformaciju podaci su normalizirani, te prema indeksima sposobnosti može se zaključiti da je proces sposoban.




Slika 46. Sposobnost procesa sporednih nosača

Koristeći Box-Cox transformaciju (slika 46.) podaci su normalizirani, ali prema indexima sposobnosti može se zaključiti da proces nije sposoban za sporedni nosač, te će se pomoću Taguchi-jevih principa nastojati poboljšati.

4.6 ANALIZA PODATAKA UPORABOM TAGUCHI-EVIH PRINCIPA



Slika 47. Sposobnost procesa glavnog nosača 1 prema Taguchi-u




Slika 48. Sposobnost sporednih nosača prema Taguchi-u

Pomoću grafa (slika 47.) možemo vidjeti daje iznos $C_{p\ m}-a$ jednak 1.16 što znači da je proces po Taguchi-evom principu izrazito sposoban i ciljan na target.


Iz grafa (slika 48.) možemo vidjeti da je iznos $C_{p\ m}-a$ izuzetno nizak. To navodi na zaključak da proces nije sposoban, niti orjentiran na target, te da stvara puno defekata. Do toga je došlo radi svrstavanja različitih veličina nosača u istu skupinu (sporedni nosači). To smo si mogli dozvoliti jer oni ne vode važnu ulogu u čitavoj konstrukciji, već su tu radi stabilnosti cijele konstrukcije.

Pri samom procesu mjerenja bilo je izrazito uočljiva oscilacija debljine između samih elemenata. To nije slučajnost ili greška proizvođača, već to ukazuje na smještenost tih elemenata. Elementi koji su ugrađeni u beton ili su na dijelu koji nije toliko izložen požaru ili je pak drugačijim načinom dodatno zaštićen imaju manje debljine premaza. Posljedice takvog postupanja se vide i na grafovima. Rezultati pokazuju da je sposobnost procesa izuzetno niska i dovodi do sumnje u proces, ali moramo uzeti navedene razloge u obzir. Inače kod pojave grešaka takvog tipa (izuzev ovog specifičnog slučaja) potrebno je dodatno nanijeti slojeve premaza.

4.7 ANALIZA PROCESA UPORABOM WEIBULLOVE RAZDIOBE



Slika 49. Sposobnost procesa uporabom Weibullove razdiobe (glavni nosač 1)




Slika 50. Sposobnost procesa uporabom Weibullove razdiobe (sporedni nosači 1)


Iznos P_{pk} (slike 49 i 50.) je mnogo manji od zadanog praga kvalitete, koji iznosi 1.33, te se može zaključiti da proces nije sposoban.

Treba imati na umu da vrijednosti P_p i P_{pk} nisu bazirane na μ i σ , već na parametrima distribucija koje promatrani podaci slijede (u ovom slučaju podaci slijede Weibullovu distribuciju).

4.8 ANALIZA PROCESA UPORABOM LOGNORMALNE RAZDIOBE



Slika 51. Sposobnost procesa uporabom Lognormalne razdiobe (glavni nosač 1)



Slika 52. Sposobnost procesa uporabom Lognormalne razdiobe (sporedni nosači 1)

Iz podataka (P_p i $P_p \mu$) se može vidjeti da proces (slike 51 i 52.) nije sposoban i da je potrebna detaljna analiza proizvodnog procesa.

Rezultati dobiveni Weibull-ovom i Lognormalnom razdiobom pokazuju da one nisu pogodne za naš proces, te da je potrebno na drugačiji način analizirati proces (normalnom razdiobom koja je provedena i rezultati su zadovoljavajući).

5. ZAKLJUČAK

Temeljem zadataka za diplomski rad pod naslovom: PROCJENA SPOSOBNOSTI PROCESA NANOŠENJA PROTUPOŽARNIH PREMAZA moguće je izvesti slijedeće zaključke:

- Bez sumnje je da će se u budućnosti u proizvodnji sve češće zahtijevati izvještaj kontrole kvalitete nekog proizvoda. Na taj će se način naručiocu dati garancija kvalitete naručenog proizvoda, no to je ujedno i dobar način kontrole samoga procesa proizvodnje kojeg treba stalno kontrolirati i usavršavati.
- Izuzetno je važno naglasiti nužnost korištenja propisanih certifikata u svemu; npr. pri konstruiranju građevine, pri odabiru adekvatne zaštite, pri mjerenju, statistici...
- Pravilnim korištenjem uputa pri mjerenju dolazimo do podataka koji omogućuju tehnologu i radniku u proizvodnji kvalitetniju pripremu proizvodnje, te lakše predviđanje eventualnih grešaka tokom proizvodnje.
- Mjerenjem se skuplja određeno iskustvo koje može poboljšati buduću kvalitetu rada, te time izbjegavanje nepotrebnih gubitaka, naročito u ekonomskom smislu.

Ovim radom izvršena je analiza debljine protupožarnog premaza na čeličnoj konstrukciji objekta naručioca Euroherc. Tako se i na ispitanoj čeličnoj konstrukciji može vidjeti da nanese premaz zadovoljava i da su prikazane vrijednosti u grafovima zadovoljavajuće za određene skupine nosača, uz pripadajuće uvjete. Glavni, nosivi nosači u potpunosti zadovoljavaju tražene uvjete, dok sekundarni nosači zbog svoje namjene u nekim elementima odskaku.

Do odstupanja je došlo radi svrstavanja različitih veličina nosača u istu skupinu, no to je prihvatljivo, jer oni ne vode važnu ulogu u čitavoj konstrukciji, već su tu radi stabilnosti cijele konstrukcije.

Elementi koji su ugrađeni u beton ili su na dijelu koji nije toliko izložen požaru ili su pak drugačijim načinom dodatno zaštićen, imaju manje debljine premaza. Raznolikost debljina dovela je do toga da ima i debljina koje ne zadovoljavaju, ali upravo zbog gore navedenih činjenica smo dokazali da se ne radi o greški.

Važno je naglasiti da su oni uvjerljivi pokazatelji kako proces za te nosače nije stabilan i da bi ga trebalo poboljšati (radi ekonomskog faktora).

Proces bi se trebao poboljšati već pri samom nanošenju prvog sloja premaza. Kod špricanja bi trebalo postaviti uvjete u takve omjere da kod nanošenja boje, nanese sloj bude ujednačen, tj. da teži nekoj jedinstvenoj, traženoj vrijednosti. Potrebno je uskladiti parametre tlaka bezračne šprice, gustoću premaza, temperaturu prostorije, obučenosť djelatnika. To možemo ostvariti ukoliko sam proces polazi od visokih preciznosti i smanjenja odstupanja. Kako bi se stvorio takav proces, potrebno ga je pratiti kroz vrijeme, te sustavno podatke o procesu odlagati u bazu iz koje će biti moguće te podatke iskoristi.

Ovakvim pristupom i njegovim stalnim usavršavanjem dolazi se do vrijednosti koje zadovoljavaju i ekonomske faktore i tražene propise. Ako na išta treba staviti naglasak u ovom radu je upravo na to da ništa ne može biti zadovoljavajuće, niti jedan korak, bez uporabe potrebnih propisa koji moraju biti međunarodno priznati. Stoga, pri kretanju u bilo kakvu investiciju nužno je osigurati potrebne dozvole i dokumentaciju koji će nas voditi kroz realizaciju zadanog projekta i uspješno nas dovesti do željenog cilja.

6. LITERATURA

- [1] Androić, B., Dujmović, D., Metalne konstrukcije 1, Institut građevinarstva Hrvatske, Zagreb, 1984.,
- [2] Pravilnik o temeljnim zahtjevima za zaštitu od požara, www.infolex.hr.,
- [3] Tehnički podaci o premazu Hensoterm 3KS Outdoor,
http://www.rudolf-hensel.de/cms/front_content.php?idcat=49&lang=3,
- [4] Norme o zaštiti od požara, nHRN DIN 4102-2,
<http://www.vzzob.hr/propisi/norme.html>,
- [5] Bass, I., Lawton, B., Lean Six sigma using Sigma XL and Minitab, McGraw-Hill Companies, 2009.,
- [6] Mudronja, V., Kontrola kvalitete, predavanja
- [7] Kolesarić, Petz, Statistički rječnik, 1999,
- [8] Minitab User Manual, www.minitab.com